
Metodología de selección de indicadores óptimos para el análisis y diagnóstico del estado de la máquina: aplicación a elementos mecánicos rotativos



TESIS DOCTORAL

Doctorado en Ingeniería Mecánica y Organización Industrial

María Jesús Gómez García

Directores

Juan Carlos García Prada

Cristina Castejón Sisamón

Departamento de Ingeniería Mecánica

Escuela Politécnica Superior

Universidad Carlos III de Madrid

Abril 2014

Metodología de selección de indicadores
óptimos para el análisis y diagnosis del estado
de la máquina: aplicación a elementos
mecánicos rotativos

Tesis doctoral
Ingeniería Mecánica
04/2014

María Jesús Gómez García

Departamento de Ingeniería Mecánica
Escuela Politécnica Superior
Universidad Carlos III de Madrid

Abril 2014

Agradecimientos

Quiero mencionar en primer lugar a los Directores de la presente Tesis Doctoral, Juan Carlos García Prada y Cristina Castejón, a los que quiero agradecer su confianza, dedicación y colaboración en todo momento.

También quiero agradecer al Departamento de Ingeniería Mecánica de la Universidad Carlos III por la oportunidad de realizar este trabajo, y más específicamente a los que a lo largo de esta etapa han sido mis compañeros en el grupo Maqlab. Algunos de ellos han contribuido a este trabajo mediante sus Proyectos de Fin de Carrera y de Fin de Máster. Otros han ayudado con sus conocimientos y consejos, y todos ellos con su respeto y grata compañía. A todos ellos, gracias.

Resumen

La detección prematura de defectos en maquinaria rotativa es fundamental para evitar fallos catastróficos y ahorrar costes, ayudando así a un correcto mantenimiento. Además, la automatización de estos procesos es fundamental para mejorar el nivel de fiabilidad y seguridad, por lo que existe una tendencia hacia un tipo de mantenimiento denominado ‘monitorización de estado’, que se basa en la monitorización continua de la condición de los elementos durante su funcionamiento. Uno de los parámetros más utilizados para decidir el estado de un elemento mecánico es su respuesta vibratoria.

Los elementos presentes en una máquina rotativa son muy diferentes y, por tanto, también lo son cada uno de los defectos que puede presentar y la manera en la que se manifiestan. En los últimos años se han desarrollado muchos trabajos en este sentido, principalmente enfocados a la detección de defectos en engranajes y rodamientos, por ser los elementos más ampliamente utilizados en maquinaria rotativa y porque el diseño de la máquina está pensado para que este tipo de elementos sean los primeros en fallar.

Para el caso de ejes, la probabilidad de fallo es menor pero éste es más crítico. También ha habido numerosas publicaciones sobre defectología en ejes, aunque este tipo de estudios se ha centrado mayoritariamente en detectar los cambios que los defectos provocan en la respuesta dinámica y no es común realizar diagnosis reales y menos en el ámbito experimental. En el caso de turbomaquinaria, a velocidades cercanas a la crítica o incluso sobrepasándola, sí existen trabajos que ofrecen buenos resultados de diagnosis en ejes utilizando su respuesta vibratoria, sin embargo a bajas velocidades este tipo de estudios no ofrecen por lo general buenos resultados, y en campos como el ferroviario, la estrategia de mantenimiento para los ejes sigue siendo preventiva. Esto implica numerosos costes porque es necesario parar y desmontar la máquina para realizar las inspecciones. Un avance en las técnicas de monitorización de estado en este tipo de campos sería muy útil para ahorrar costes y aumentar la seguridad.

En la presente Tesis Doctoral, se han desarrollado y aplicado diferentes técnicas para detectar defectos en ejes a través de su respuesta vibratoria durante su funcionamiento a bajas velocidades, alejadas de la crítica. Para ello se han utilizado diversas herramientas que trabajan tanto en el dominio del tiempo como en la frecuencia para encontrar posibles indicadores de defecto. Posteriormente, para cada posible indicador, se han estudiado diferentes sistemas de clasificación para automatizar la decisión sobre el estado del elemento. Finalmente el estudio ha desembocado en el desarrollo de una metodología general que permite encontrar la técnica de diagnosis óptima, en cuanto a fiabilidad y coste computacional. El trabajo, que inicialmente se ha centrado en ejes, posteriormente ha sido aplicado con éxito a rodamientos, demostrando que es posible generalizar la metodología a otro tipo de elementos mecánicos rotativos.

Abstract

Early detection of defects in rotating machinery is essential to avoid catastrophic failures and to save costs, helping to get a proper maintenance. The automating of these processes is also very important to improve the reliability and safety levels, reason why nowadays there is a tendency towards a type of maintenance called ‘condition monitoring’, based in the continuous monitoring of the condition of the elements while they are working. One of the parameters most used to decide the status of the machine is its vibratory response.

The elements present in a rotating machine are very different, so the defects that can be present and the way they show are also very different. In the last years there are a lot of published works focused in fault detection in gears and bearings. These kinds of elements are the most widely used in rotating machinery, and they are usually the first to failure.

For the case of shafts, the probability of failure is lower, however in case of appearing is much more critical. For this type of elements there are also a lot of works studying its dynamical behavior when a crack appears, nevertheless it has not been very common to translate these results in real diagnosis and less in experimental cases. In turbomachinery, working with high speeds close to the critical speed, there are works that offer good diagnosis results in shafts by means of its vibratory response, however at low speeds it is not common, and for example in the railway field, the maintenance strategy is nowadays preventive. An improving in condition monitoring techniques applied to shafts in this kind of field would be very useful to save cost and improve safety.

In the present Doctoral Thesis, different techniques have been developed and applied to detect defects in shafts through its vibratory response during working at low speeds (far from the critical one). For this purpose diverse tools that work in time and in frequency domain have been applied to find indicators of crack. Afterwards, for each indicator, several classification systems have been studied to automate the decision about the status of the element. The study finally led in the development of a general methodology that allows finding the optimal diagnosis technique, regarding reliability and computational cost. The work developed in shafts has been applied successfully to diagnose bearings, showing that it is possible to generalize the methodology to other kind of rotating elements. All the results obtained have been validated experimentally.

Lista de Acrónimos

AE *Acoustic Emission*, emisión acústica. 15

ANN *Artificial Neural Network*, red neuronal artificial. 14, 17, 43, 45, 46, 48, 49, 95, 98, 106, 110

BPFI *Ball Pass Frequency Inner Race*, frecuencia de paso de la bola por la pista interna. 16

BPFO *Ball Pass Frequency Outer Race*, frecuencia de paso de la bola por la pista externa. 16

BPFR *Ball Pass Frequency Roller*, frecuencia de paso de un defecto en la bola. 16

BSF *Ball Spin Frequency*, frecuencia característica de defecto en bola. 16

CS2 Cicloestacionaridad de segundo orden. 17

CWT *Continuous Wavelet Transform*, transformada Wavelet continua. 35–37

DFT *Discrete Fourier Transform*, transformada discreta de Fourier. 31, 33

DWT *Discrete Wavelet Transform*, transformada Wavelet discreta. 37, 38

EMD *Empirical Mode Decomposition*, descomposición empírica en modos. 17

FFT *Fast Fourier Transform*, transformada rápida de Fourier. 15, 17, 31–33, 57, 62, 73

FL *Fuzzy logic*, Lógica Borrosa. 14, 17, 45

FT *Fourier Transform*, transformada de Fourier. 31

FTF *Fundamental Train Frequency*, frecuencia característica de defecto en jaula. 16

GA *Genetic Algorithms*, algoritmos genéticos. 45

HHT *Hilbert-Huang Transform*, transformada Hilbert-Huang. 17

HT *Hilbert Transform*, transformada Hilbert. 17, 34

IMF *Intrinsic Mode Functions*, funciones de modos intrínsecos. 17

MLP *Multilayer Perceptron*, red neuronal perceptrón multicapa. 48

- MRA** *Multiresolution Analysis*, análisis multiresolución. 38, 66, 134
- MSE** *Mean Squared Error*, error cuadrático medio. 49–51, 99, 100, 103
- NDT** *Non Destructive Testing*, técnicas de inspección no destructiva. 9, 13
- PNN** *Probabilistic Neural Network*, red neuronal probabilística. 48, 49
- POD** *Probability of Detection*, probabilidad de detección. 3, 4, 19, 21, 24, 25, 43, 59, 66, 78–80, 86, 87, 89, 91, 94, 100–103, 106, 107, 110, 114
- PR** *Pattern Recognition*, reconocimiento de patrones. 45
- PSD** *Power Spectral Density*, densidad de potencia espectral. 34, 56, 65, 66
- QMF** *Quadrature Mirror Filters*, filtros espejo en cuadratura. 35
- RAMS** *Reliability, Availability, Maintainability and Safety*, fiabilidad, disponibilidad, mantenibilidad y seguridad. 1
- RBF** *Radial Basis Function*, función de base radial. 25, 43, 47–50, 99–101, 105–107, 110, 114, 135
- RMS** *Root Mean Square*, raíz cuadrática media. 29
- SERR** *Strain Energy Release Rate*, velocidad de liberación de energía de deformación. 10–12
- STFT** *Short Time Fourier Transform*, transformada de Fourier de tiempo corto. 15, 33, 35
- SVM** *Support Vector Machines*, máquinas de soporte vectorial. 14, 15, 17, 45
- WPT** *Wavelet Packets Transform*, transformada en paquetes Wavelet. 7, 38–42, 66, 67, 72–74, 76, 78–80, 93, 95, 107, 109–111, 113, 114, 133–135, 138
- WT** *Wavelet Transform*, transformada Wavelet. 5, 14, 15, 28, 35, 39, 65, 115

Índice

Agradecimientos	v
Resumen	vii
Abstract	ix
Lista de Acrónimos	xii
1. Introducción y objetivos	1
1.1. Ámbito general	1
1.2. Monitorización de estado	2
1.2.1. Curvas POD	3
1.3. Objetivos	5
1.3.1. Objetivo General	5
1.3.2. Objetivos específicos	5
1.4. Estructura del documento	6
1.5. Aportaciones científicas	7
2. Estado del arte	9
2.1. Trabajos previos en defectología de ejes	10
2.1.1. Rotodinámica	10
2.1.2. Técnicas de detección de defectos en ejes	13
2.2. Trabajos previos en defectología de rodamientos	15
3. Metodología propuesta	19
3.1. Metodología general	19
3.2. Diseño de la metodología experimental y adquisición de datos	20
3.3. Extracción y selección de posibles patrones válidos	21
3.3.1. Selección de parámetros locales de la señal	23
3.4. Diseño del sistema de clasificación	24
4. Procesamiento de señales en defectología	27
4.1. Parámetros basados en el dominio del tiempo	28
4.1.1. Medidas de centralización de la señal	28
4.1.2. Medidas de dispersión de la señal	29
4.1.3. Medidas relativas a la forma de la señal	29

4.1.4.	Otros parámetros de interés	29
4.2.	Parámetros basados en el dominio de la frecuencia	30
4.2.1.	Transformada rápida de Fourier	31
4.2.2.	Densidad de potencia espectral	34
4.2.3.	Transformada Hilbert	34
4.3.	Parámetros en el dominio del tiempo y frecuencia. La transformada Wavelet . . .	35
4.3.1.	Transformada Wavelet continua	35
4.3.2.	Transformada Wavelet discreta	37
4.3.3.	Análisis multiresolución	38
4.3.4.	Transformada en paquetes Wavelet	38
5.	Sistemas de clasificación para diagnóstico	43
5.1.	Clasificación mediante el método ‘ \hat{a} vs. a ’	43
5.2.	Clasificación inteligente mediante redes neuronales artificiales	45
5.2.1.	Redes con función de base radial	50
6.	Sistema experimental	53
6.1.	Banco de ensayos	53
6.2.	Diseño de la metodología experimental	54
6.2.1.	Ensayos preliminares	54
6.2.2.	Cadena de medida	57
6.2.3.	Condiciones de los ensayos	57
6.2.4.	Defectos a estudiar	58
6.2.5.	Número de medidas a tomar	60
6.3.	Protocolo de medidas	61
6.4.	Adquisición de datos: base de datos generada	62
7.	Desarrollo y resultados: aplicación de la metodología propuesta	65
7.1.	Selección de parámetros locales según los resultados teóricos	66
7.1.1.	Modelo de rotor Jeffcott con función de respiro	67
7.1.2.	Análisis de las energías del modelo teórico	73
7.1.3.	Análisis de energías de las señales experimentales en las frecuencias de fallo	78
7.1.4.	Diseño del sistema de clasificación: método de señal de respuesta	79
7.1.5.	Resultados	87
7.1.6.	Resumen	93
7.2.	Selección de parámetros locales según los resultados experimentales	95
7.2.1.	Análisis global de energías de las señales experimentales	95
7.2.2.	Diseño del sistema de clasificación: redes neuronales RBF	99
7.2.3.	Resultados	101
7.2.4.	Resumen	105
7.3.	Comparativa de resultados y selección de la técnica óptima	106
7.4.	Aplicación de la metodología propuesta a otros elementos mecánicos rotativos . .	107
8.	Conclusiones y futuros desarrollos	109
8.1.	Conclusiones	109

8.2. Futuros desarrollos	111
Bibliografía	124
APÉNDICES	126
A. Hojas de características de los acelerómetros	127
B. Protocolo de medidas	131
C. Aplicación de metodología propuesta a rodamientos	133
C.1. Adquisición de datos	133
C.2. Análisis de las energías WPT de las frecuencias teóricas de fallo	134
C.3. Análisis global de la energía WPT de las señales experimentales	135
C.3.1. Diseño del sistema de clasificación: redes neuronales RBF	135
C.3.2. Resultados	135
C.4. Resumen	138

Índice de figuras

1.1. Esquema de los procesos actuales en la monitorización de estado	3
1.2. Gráfica POD ideal	4
2.1. Función de respiro propuesta por Gash	11
2.2. Función de respiro propuesta por Mayes and Davies	12
2.3. Modelo de rotor Jeffcott	13
2.4. Elementos y geometría de rodamientos	16
3.1. Esquema general de la metodología propuesta	20
3.2. Metodología propuesta para la adquisición de señales a partir del sistema mecánico	21
3.3. Metodología propuesta para la extracción de posibles patrones válidos	23
3.4. Metodología propuesta para la selección de parámetros locales	24
3.5. Metodología propuesta para la selección de patrones	25
4.1. Error en la FFT debido al ‘aliasing’	32
4.2. Error en la FFT debido la ventana temporal	32
4.3. Solución del error en la FFT debido la ventana temporal	33
4.4. Familias de Wavelets madre más utilizadas	36
4.5. Señal temporal y su transformada Wavelet continua	37
4.6. Descomposición DWT mediante filtros	38
4.7. Esquema del análisis multiresolución, procedimiento de descomposición hasta nivel 3	39
4.8. WPT análisis, procedimiento de descomposición hasta nivel 3	39
4.9. Señal descompuesta mediante WPT: filtros y downsampling	40
4.10. Orden de frecuencias obtenido tras aplicar WPT	41
4.11. Energías relativas de una señal obtenida mediante WPT a nivel 3	42
5.1. Valor umbral para el método de señal de respuesta	44
5.2. Esquema de neurona artificial básica	46
5.3. Esquema de red neuronal artificial básica	48
5.4. Comparación de arquitecturas de red neuronal comunes	49
5.5. Gráficas para la selección del valor de <i>spread</i> óptimo	51
6.1. Banco de ensayos Rotokit	54
6.2. Plano del eje	55
6.3. PSD de una señal temporal obtenida con el acelerómetro 1	56
6.4. Cadena de medida	58

6.5. Defecto generado en un espécimen	60
6.6. Parámetros definidos en la herramienta Btool para la adquisición de datos	62
6.7. Señal temporal obtenida del sistema experimental	63
6.8. FFT de la señal temporal obtenida de forma experimental	63
7.1. Modelo de rotor Jeffcott implementado en variables de estado	69
7.2. Señales temporales obtenidas del modelo teórico a 20Hz	71
7.3. FFT de las señales obtenidas del modelo teórico a 20Hz	72
7.4. Patrón obtenido mediante el cálculo de energías WPT a nivel de descomposición 9	73
7.5. Cálculo de las diferencias de energías entre eje sano y eje con defecto	75
7.6. Incrementos relativos de energía para el modelo teórico a 20Hz	76
7.7. Incrementos relativos de energía para el modelo teórico a 40Hz	77
7.8. Incrementos relativos de energía para el modelo teórico a 60Hz	77
7.9. Incrementos relativos de energía total para el modelo teórico	78
7.10. Energías obtenidas para una señal experimental para eje sano a 20Hz	79
7.11. Distribución de los logaritmos del paquete vecino a 3x a 20Hz	81
7.12. Distribución de las medias muestrales del paquete vecino a 3x a 20Hz	82
7.13. Distribución de las medias de los datos para el paquete 3x a 20Hz	83
7.14. Distribución de las medias de los datos de energía total a 20Hz	83
7.15. Distribución de las medias de los datos para el paquete vecino a 3x a 40Hz	84
7.16. Distribución de las medias de los datos para el paquete 3x a 40Hz	84
7.17. Distribución de las medias de los datos de energía total a 40Hz	85
7.18. Distribución de las medias de los datos para el paquete vecino a 3x a 60Hz	85
7.19. Distribución de las medias de los datos para el paquete 3x a 60Hz	86
7.20. Distribución de las medias de los datos de energía total a 60Hz	86
7.21. POD para el paquete vecino a 3x a 20Hz	87
7.22. POD para el paquete 3x a 20Hz	88
7.23. POD para las energías totales a 20Hz	88
7.24. POD para el paquete vecino a 3x a 40Hz	89
7.25. POD para el paquete 3x a 40Hz	90
7.26. POD para las energías totales a 40Hz	90
7.27. POD para el paquete vecino a 3x a 60Hz	91
7.28. POD para el paquete 3x a 60Hz	92
7.29. POD para las energías totales a 60Hz	92
7.30. Regresión de los datos de logaritmos de energías del paquete vecino a 3x a 60Hz	93
7.31. Metodología de selección de paquetes óptimos	96
7.32. Selección del nivel de descomposición óptimo a 20Hz	101
7.33. PODs obtenidas de las RBFs para niveles de descomposición bajos a 20Hz	102
7.34. PODs obtenidas de las RBFs para niveles de descomposición altos a 20Hz	103
7.35. POD a nivel de descomposición 5 y <i>goal</i> 0,1 a 20Hz	104
7.36. POD a nivel de descomposición 5 y <i>goal</i> 0,1 a 40Hz	104
7.37. POD a nivel de descomposición 5 y <i>goal</i> 0,1 a 60Hz	105
7.38. Comparación de las curvas POD óptimas obtenidas por cada método	106
7.39. Tasas de acierto desglosadas para las redes en el caso de los rodamientos	108

A.1. Hoja de características del acelerómetro 1	128
A.2. Hoja de características del acelerómetro 2	129
A.3. Hoja de características del acelerómetro 3	130
C.1. Banco de ensayos utilizado para la toma de medidas de rodamientos	134
C.2. Selección del valor de descomposición óptimo en rodamientos	136
C.3. Tasas de acierto desglosadas para las redes en el caso de los rodamientos	137

Índice de Tablas

1.1. Posibles escenarios para los resultados de la clasificación	4
5.1. Parámetros de diseño de las redes RBF	50
6.1. Propiedades mecánicas del eje	54
6.2. Propiedades de los acelerómetros	55
7.1. Bandas de frecuencia significativas para el modelo teórico	74
7.2. Bandas de frecuencia significativas para el sistema experimental	80
7.3. Bandas de frecuencia significativas a la velocidad de 20Hz	97
7.4. Bandas de frecuencia significativas a la velocidad de 40Hz	97
7.5. Bandas de frecuencia significativas a la velocidad de 60Hz	98
7.6. Selección de los patrones de entrada según el nivel de descomposición	99
7.7. Parámetros de diseño de las redes RBF	101
7.8. Comparación de tiempos de ejecución de los dos métodos de diagnosis	107
C.1. Frecuencias de fallo de los rodamientos FAG 7206 B	135
C.2. Constantes utilizadas para el diseño de RBFs en rodamientos	136
C.3. Resultados obtenidos para un <i>goal</i> de 0,1	137

Capítulo 1

Introducción y objetivos

1.1. Ámbito general

El rendimiento de todo proceso industrial está directamente relacionado con la capacidad de servicio de los sistemas mecánicos que utiliza. Un aspecto esencial para mejorar la capacidad de producción o de funcionamiento de un proceso es la realización de un mantenimiento adecuado. Hoy en día, a nivel industrial, es fundamental realizar un tipo de estudio denominado RAMS (del inglés *Reliability, Availability, Maintainability and Safety*, fiabilidad, disponibilidad, mantenibilidad y seguridad) que permite pronosticar, para un periodo determinado de tiempo, el factor de servicio de un proceso de producción, dependiendo de la configuración, la fiabilidad de sus componentes, y el tipo de mantenimiento realizado.

La fiabilidad y la disponibilidad de un sistema mecánico representan la capacidad del mismo para operar correctamente, y ésta depende de las tasas de fallo de cada elemento, los modos de fallo, los efectos de un fallo en la funcionalidad del sistema, el tipo de aplicación, el entorno, etc.

La **mantenibilidad** está directamente relacionada con el mantenimiento, área en la que se puede situar la presente Tesis Doctoral. Consiste en la capacidad de un sistema mecánico de ser mantenido, que es mayor cuanto menores son la duración y el esfuerzo de las tareas de mantenimiento. Así, la mantenibilidad se ve afectada por el tiempo para la realización del mantenimiento, la frecuencia, y el tiempo para la detección, identificación, localización e intervención cuando existe un fallo. Un correcto mantenimiento puede reducir en gran medida los costes y aumentar la seguridad.

Durante el desarrollo industrial se han aplicado varias filosofías de mantenimiento. La primera de estas filosofías es el mantenimiento correctivo, que consiste en la reparación de averías o fallos funcionales a medida que van ocurriendo. Estas acciones de mantenimiento se presentan de forma no controlada. Una evolución del mantenimiento correctivo es el preventivo, que tiene como fundamento la realización de paradas programadas para sustitución de piezas y lubricación de mecanismos, cuyos intervalos se fijan en base a la estadística de equipos similares y respetando las recomendaciones de los fabricantes. La finalidad del mantenimiento preventivo es la de disminuir paradas no programadas y que éstas sean realizadas en el mejor momento. Su mayor inconveniente es el desperdicio de vida útil remanente de los elementos sustituidos, que podría ser utilizada mejorando el rendimiento del sistema productivo.

El mantenimiento predictivo, también llamado monitorización de estado (o en inglés *condition-based maintenance* o *condition monitoring*), constituye la siguiente evolución. Este tipo de mantenimiento tiene la estrategia de evaluar el estado de la máquina mientras está en funcionamiento, mediante la monitorización de varios parámetros mecánicos. Basándose en esto, se establecen unos patrones de normalidad de funcionamiento. Cuando estos patrones son vulnerados y se detecta algún tipo de defecto, se establece aproximadamente el tiempo que resta a la ocurrencia del fallo, programando así una intervención en el momento más adecuado.

Las técnicas más utilizadas hoy en día para monitorizar el estado de una máquina son la inspección visual y sonora, análisis de lubricantes, termografías, medidas de temperatura, análisis de corrientes del motor, y análisis de vibraciones, entre otros. En máquinas rotativas cobra especial importancia el análisis de vibraciones ya que, realizado correctamente, puede proporcionar información valiosa sobre los fallos.

Debido a que los engranajes y rodamientos son los componentes más utilizados en maquinaria rotativa, las técnicas de monitorización han sido más ampliamente desarrolladas para ellos. Además, los rodamientos son los elementos que presentan mayor probabilidad de fallo. Ésto va implícito en el diseño de la máquina: es preferible verse obligado a sustituir un rodamiento que otro tipo de elementos. Sin embargo, se han dado casos en los que el primer elemento en romperse ha sido el eje, provocando, además, consecuencias catastróficas para la totalidad de la máquina y para las personas y elementos circundantes. Para el caso de ejes ha habido muchos avances a nivel teórico sobre el comportamiento dinámico de los mismos cuando aparece un defecto, pero no es habitual aplicar el proceso inverso de detección de defectos y menos a nivel experimental.

La presente tesis doctoral se enmarca en el ámbito del mantenimiento predictivo, y pretende avanzar en las técnicas de monitorización de estado de elementos mecánicos, centrándose principalmente en ejes por ser las menos desarrolladas, pero teniendo también en cuenta la posible generalización de las técnicas propuestas a la monitorización de otros elementos mecánicos, como los rodamientos.

1.2. Monitorización de estado

El principal objetivo de la monitorización de estado en maquinaria rotativa es detectar defectos antes de que se produzca un fallo crítico y, además, con la suficiente antelación para programar una parada de la máquina en el momento más conveniente. Este tipo de mantenimiento tiene muchas ventajas porque elimina la necesidad de parar y desmontar la máquina para comprobar el estado de sus elementos. Además, la probabilidad de detectar un fallo antes de que sea grave aumenta, evitando así pérdidas e incrementando la seguridad de los procesos. Por estas razones la monitorización de estado en procesos industriales ha sido objeto de numerosas investigaciones en las últimas décadas.

En un procedimiento industrial, cuando aparece un defecto durante la monitorización, se pasa por tres etapas diferenciadas: en primer lugar, la detección del defecto, posteriormente la diagnosis, que consiste en determinar de qué tipo es, y por último la intervención para corregir

los efectos indeseados. La monitorización normalmente se basa en la identificación de patrones de comportamiento, para poder detectar posibles anomalías y entonces avisar de la ocurrencia de un fallo. Hoy en día, la monitorización de las señales vibratorias generadas por las máquinas está muy extendida.

Una señal vibratoria adquirida en una máquina rotativa en funcionamiento requiere de un gran número de datos para representar su complejo comportamiento. Este tipo de señales, por tanto, necesita un procesamiento que ha de ser elegido de manera que aumente la manejabilidad de la información, y a su vez se extraigan características relevantes de las señales que permitan conocer el estado real de la máquina. A estas transformaciones de la señal se le llama habitualmente **extracción de patrones**. Los patrones, que contienen información sobre el defecto, necesitan de un sistema de clasificación que automatice el proceso y decida la diagnosis del estado del elemento mecánico que se ofrece como salida. El objetivo de este tipo de sistemas es obtener un diagnóstico de forma automática, evitando que un operario tenga que tomar una decisión sobre el estado del elemento mecánico, eliminando así factores humanos.

El proceso seguido en este tipo de análisis es el que se muestra en la figura 1.1.




Figura 1.1: Esquema de los procesos actuales en la monitorización de estado

1.2.1. Curvas POD

La probabilidad de detectar un defecto mediante una determinada técnica se calcula fundamentalmente utilizando métodos estadísticos a partir de los resultados experimentales, ya que las inspecciones realizadas sobre defectos del mismo tamaño y del mismo tipo no ofrecen siempre la misma respuesta. Por tanto, para cada condición de defecto presente en el sistema mecánico, es necesario tener un conjunto representativo de respuestas que permita conocer sus posibles fluctuaciones.

Después de realizar una inspección sobre un elemento mecánico, el sistema de clasificación decide si el elemento está sano o defectuoso. Por tanto en este tipo de clasificaciones hay cuatro posibles escenarios según Bachsmid [1], tal y como se muestra en la tabla 1.1.

	Defecto presente	Defecto ausente
Resultado de inspección positivo	<i>Verdadero positivo</i>	<i>Falso positivo</i>
Resultado de inspección negativo	<i>Falso negativo</i>	<i>Verdadero negativo</i>

Tabla 1.1: Posibles escenarios para los resultados de la clasificación, en función de si existe o no defecto, y el diagnóstico de la clasificación

Cualitativamente, la fiabilidad de un método de inspección no destructiva se puede definir como la probabilidad de detección de un defecto de un determinado rango de tamaños bajo unas determinadas condiciones de inspección y procedimientos [2]. Ésto se suele representar mediante curvas de probabilidad de detección (POD, del inglés *Probability of Detection*), que son un parámetro universalmente aceptado para evaluar la validez de una técnica de diagnosis de defectos y, por tanto, serán utilizadas para presentar los resultados de la presente Tesis Doctoral.

Las curvas POD representan, por tanto, la probabilidad de que el sistema diagnostique un defecto para cada condición evaluada. Cada una de las condiciones evaluadas está definida mediante un parámetro relativo al tamaño del mismo (diámetro, longitud, profundidad, etc.). El escenario ideal es que el sistema tenga una probabilidad del 0 % de afirmar que existe un defecto cuando se inspecciona el elemento sano (defecto cero), y que adquiera el valor del 100 % para los distintos niveles de defecto (D1, D2, etc.), tal y como se muestra en la figura 1.2.




Figura 1.2: Gráfica POD ideal respecto a la condición del eje (eje sano o defecto cero y los defectos evaluados en este trabajo D1, D2, etc.)

Para generar las curvas de probabilidad de detección se atiende a los resultados experimentales sobre inspecciones de resultado conocido. Sin embargo, los resultados obtenidos dependen del parámetro característico utilizado para definir el tamaño del defecto, así como del método de inspección, del material, la geometría del defecto, y posibles influencias humanas y del entorno. En este trabajo, concretamente en las técnicas aplicadas a ejes, las curvas se representarán en

función de la sección del eje afectada por el defecto ya que, según [3], este parámetro permite hacer independiente la respuesta de la geometría del defecto: es decir, defectos que afectan a la misma sección del eje provocan la misma respuesta, independientemente de su geometría.

1.3. Objetivos

Los objetivos de la presente Tesis Doctoral son:

1.3.1. Objetivo General

El objetivo general es desarrollar una metodología que permita establecer y validar una técnica óptima de diagnóstico de defectos en un elemento mecánico rotativo particular, basándose en el análisis de señales vibratorias obtenidas durante el funcionamiento de la máquina (a bajas velocidades en estado estacionario), con el fin de mejorar el mantenimiento de los mismos. La metodología se desarrollará y validará para el caso de sistemas de transmisión (ejes y rodamientos).

1.3.2. Objetivos específicos

Los objetivos específicos que se plantean para la consecución del objetivo general son:

- Diseño y aplicación de una metodología para establecer y validar una técnica óptima de diagnosis de defectos para ejes en el banco de ensayos Rotokit, mediante los siguientes pasos:
 - Realización de un estudio teórico sobre ejes, con el fin de conocer las características dinámicas de los mismos en presencia de un defecto. En el caso de que no haya consenso en la bibliografía, será necesario realizar un modelo analítico del elemento de análisis.
 - Diseño de una metodología experimental, representativa de las condiciones nominales de la máquina de que se dispone, que permita la obtención de señales vibratorias para el elemento de estudio sano y para el elemento en condiciones de defecto.
 - Obtención de señales vibratorias con el fin de estudiar las diferencias en el comportamiento dinámico de la máquina analizada cuando el eje está sano y cuando está defectuoso.
 - Selección de los parámetros, o características de la señal vibratoria, que puedan ser posibles patrones válidos para la diagnosis de defectos al presentar diferencias notables en sus valores cuando el eje está sano y defectuoso. Esta selección se debe llevar a cabo apoyada por el estudio teórico, pero además ha de basarse en el estudio de las señales experimentales. Aquellos parámetros que sean de aplicación compleja, por la cantidad de parámetros a definir, como la transformada Wavelet (WT, del inglés *Wavelet Transform*), deben ser optimizados.
 - Diseño de diferentes sistemas de clasificación en busca del óptimo para cada posible patrón válido, y posterior análisis cuantitativo (en cuanto a fiabilidad y coste computacional) de los diferentes métodos analizados.
 - Selección de los patrones, sistema de clasificación y condiciones de operación que presentan la diagnosis óptima de entre todas las posibilidades examinadas.

- Aplicación de la metodología desarrollada para establecer un sistema de diagnosis fiable para otros elementos mecánicos, como el caso de rodamientos, con el fin de comprobar su posible generalización.

1.4. Estructura del documento

El documento de la presente Tesis Doctoral está estructurado en 8 capítulos y 3 apéndices.

Antes del índice de capítulos se puede consultar una lista de los acrónimos utilizados.

En el capítulo 1 se presenta una introducción, así como los objetivos generales y específicos del mismo y las aportaciones científicas.

En el capítulo 2 se desarrolla el estado del arte sobre los procesos de diagnosis de defectos en máquinas, concretamente se especificarán las técnicas más utilizadas para los elementos de interés: ejes y rodamientos.

En el capítulo 3 se presenta la metodología llevada a cabo para la consecución de los objetivos, incluyéndose todos los procesos detallados.

En el capítulo 4, y a la vista del estudio bibliográfico, se detallan las herramientas matemáticas utilizadas para la transformación de las señales y, por tanto, para la selección de posibles patrones válidos.

En el capítulo 5, se describen los sistemas clasificadores utilizados, y se detallan sus procesos de diseño.

En el capítulo 6 se describen, tanto el sistema mecánico utilizado como el proceso de diseño de la metodología experimental y la adquisición de datos.

En el capítulo 7, se presenta la aplicación práctica de la metodología mediante la cual, en primer lugar, se descartan los parámetros que no parecen ser patrones válidos para la detección de defectos. Una vez seleccionado un grupo de posibles patrones válidos, se diseñan los sistemas de clasificación para cada uno y se comparan sus resultados (tanto en términos de fiabilidad como de coste computacional) y se selecciona la metodología óptima.

En el capítulo 8, se presentan las conclusiones y las futuras líneas de investigación que deja abiertas la presente Tesis Doctoral.

A continuación se puede consultar la bibliografía utilizada, y finalmente se incluyen los tres apéndices del documento.

En el apéndice A, se presentan las hojas de características de los acelerómetros disponibles para utilizar en el presente trabajo, de los que finalmente se escoge el acelerómetro número 3.

En el apéndice B, se presenta el protocolo de medidas seguido para la adquisición de datos

para diferentes condiciones de defecto en ejes.

En el apéndice C, se presentan los resultados de la aplicación metodología para señales vibratorias obtenidas de rodamientos en diferentes condiciones de fallo.

1.5. Aportaciones científicas

La principal aportación de la presente Tesis Doctoral es el desarrollo de una metodología general para detectar defectos en elementos mecánicos rotativos. Después de estudiar y desarrollar varias técnicas de diagnóstico fiables, comprobadas experimentalmente, la metodología permite optimizar todos los parámetros y obtener la mejor diagnosis posible.

Las aportaciones científicas de la presente Tesis Doctoral son:

- La selección y utilización de la energía de la señal vibratoria, procesada mediante la transformada en paquetes Wavelet (WPT, del inglés *Wavelet Packets Transform*), como patrón óptimo para detectar defectos en elementos mecánicos rotativos. Se presenta un estudio detallado del patrón para esta utilidad. Además, en este trabajo se prescinde de la normalización que usualmente se aplica para calcular este parámetro, donde las energías son relativas respecto a la energía global de la señal vibratoria. Las energías de la WPT utilizadas en este trabajo se presentan en valores absolutos.
- Para el caso de ejes, se ha desarrollado un método de diagnosis fiable, comprobado experimentalmente, a partir de los cambios de energía en el tercer armónico de la velocidad de giro (3x). En la bibliografía, tradicionalmente se han utilizado las frecuencias 1x y 2x (armónicos de la velocidad de giro), con resultados poco fiables en la práctica. Como aportación adicional en este punto, se ha establecido una correlación entre los valores del patrón y el tamaño del defecto.
- El uso de las energías de la WPT para la extracción de patrones ha permitido el desarrollo de un proceso automático para detectar las bandas de frecuencia, o paquetes, que presentan mayores cambios de energía cuando aparece un defecto. Este método está basado en la utilización de redes neuronales, que permiten seleccionar los parámetros (tanto del nivel de descomposición de la WPT, como la disposición de los patrones) con los que se consiguen los mejores resultados de clasificación.

Es decir, la conjunción de todas las técnicas de diagnóstico estudiadas ha dado como resultado la aportación fundamental de la presente Tesis Doctoral, que es la metodología general propuesta. Esto supone una gran innovación, ya que las técnicas propuestas han sido validadas experimentalmente tanto en su aplicación a ejes como a rodamientos. La metodología propuesta permite obtener la configuración óptima de los parámetros necesarios para un diagnóstico fiable de defectos en elementos rotativos de un sistema mecánico. La ventaja principal de esta técnica, es que está encaminada a realizar el diagnóstico durante el funcionamiento de la máquina.

Capítulo 2

Estado del arte

La diagnosis de defectos puede realizarse como parte del mantenimiento predictivo o monitorización de estado de un sistema. A lo largo de la historia, las contribuciones han sido muy diversas en este campo: en el pasado más reciente, a través de la caracterización espectral de componentes, y en la actualidad, la tendencia es automatizar la mayor parte del proceso de monitorización, e implicar mucho menos el factor humano [4].

Es bien sabido que la aparición de un defecto en un elemento estructural genera una flexibilidad local, provocando un cambio en su rigidez [5]. Como consecuencia, las frecuencias naturales se ven reducidas y los modos de vibración también se ven alterados, hecho que ha sido utilizado tradicionalmente para intentar detectar defectos en estructuras. Principalmente se atiende a la reducción en las frecuencias naturales, ya que sus valores se pueden obtener de forma sencilla midiendo vibraciones en un punto de la estructura [6]. Sin embargo, estas técnicas tienen una desventaja muy importante, y es que las variaciones en la frecuencia natural son insignificantes para las necesidades prácticas. Otro de los métodos propuestos en este sentido consiste en utilizar la relación entre las amplitudes de la aceleración y la excitación como indicador de defecto, ya que los defectos provocan cambios en la transmisibilidad de las vibraciones forzadas, según Akgun en [7]. Estas técnicas también muestran limitaciones en la práctica a la hora de detectar defectos en estructuras.

Es común, por tanto, recurrir a técnicas de inspección no destructiva (NDT, del inglés *Non Destructive Testing*), como los ultrasonidos o las partículas magnéticas, mediante las cuales se realizan inspecciones durante paradas periódicas programadas (como en el caso de ejes ferroviarios). Dichas técnicas tienen limitaciones, en el caso de los ultrasonidos debido a su reducida fiabilidad en zonas de cambios de sección, y en el caso de las partículas magnéticas a la dificultad para automatizar los procesos. Además, para ambas técnicas es necesario acceder a las superficies, lo que implica la obligación de desmontar los elementos mecánicos con los costes que conlleva [8].

Para el caso de maquinaria rotativa se han intentado utilizar, como medio para la diagnosis, los cambios en la respuesta dinámica vibratoria cuando aparece un defecto. Además, esto permite la posibilidad de realizar una monitorización de estado. Debido a ello, en las últimas cinco décadas han aparecido numerosos trabajos estudiando el comportamiento dinámico de ejes y maquinaria rotativa con la presencia de un defecto. El interés creciente en este campo se debe a que la rotura de un elemento de este tipo puede ocasionar una situación muy crítica, y con elevados riesgos para las personas, la propia máquina y equipos circundantes. Según señalan Bachschmid y Penacci en [9], a pesar de los numerosos estudios del comportamiento dinámico de maquinaria rotativa, pocos son los trabajos que presentan resultados experimentales de diagnosis. Normalmente los

resultados se obtienen de modelos y no es habitual el planteamiento del problema inverso de identificación de defectos.

Los rodamientos y engranajes, que son los elementos más utilizados en maquinaria rotativa, tienen configuraciones más complejas que los ejes. Es por ello que su respuesta dinámica permite la detección de defectos de una manera más sencilla que para el caso de ejes. Son numerosos los trabajos que estudian la detección de defectos en rodamientos y engranajes, presentando además resultados experimentales.

En las siguientes secciones, se detallarán las técnicas más utilizadas en los últimos años para la diagnosis de defectos de los principales elementos de interés de la presente Tesis Doctoral: los ejes y los rodamientos.

2.1. Trabajos previos en defectología de ejes

Los ejes están destinados a transmitir el movimiento rotativo entre elementos. Son muy robustos y están diseñados con un elevado factor de seguridad. Sin embargo, son serios candidatos a sufrir defectos debido a fatiga, ya que las tensiones de flexión que soportan tienen naturaleza fluctuante. Normalmente, las grietas se inician por sucesos que incrementan las tensiones mecánicas como defectos de forja, tensiones superficiales, porosidad, huecos, etc. Una vez que una grieta se ha iniciado, debido a la naturaleza cíclica de las tensiones soportadas, las discontinuidades crecen. En este sentido, las condiciones de operación y de fabricación del eje son factores que determinan la velocidad de crecimiento de una fisura, que suele aumentar de forma exponencial con el tamaño del defecto [10].

A continuación se presenta una revisión de los trabajos publicados en los últimos años sobre defectología en ejes.

2.1.1. Rotodinámica

El principal objetivo de los estudios en el campo de la defectología de maquinaria rotativa en los últimos años ha sido el de conocer la respuesta dinámica de un rotor fisurado. De este modo, la manera de modelar o cuantificar la flexibilidad local inducida por una fisura ha sido objeto de numerosas investigaciones. Una de las principales teorías desarrolladas es la de la velocidad de liberación de energía de deformación (SERR, del inglés *Strain Energy Release Rate*), combinada con teorías de rotodinámica y mecánica de la fractura. Papadopoulos en 2008 publica un estado del arte de dicha técnica y su aplicación en el modelado de fisuras [11].

Según esta teoría, una fisura en un elemento estructural introduce flexibilidades locales tanto en la dirección de la misma como en la perpendicular. Por tanto, si el elemento es rodante, la rigidez en una determinada dirección será variable en el tiempo. Son muchos los tipos diferentes de grietas que pueden aparecer en un eje, dependiendo de su forma, dirección, evolución y comportamiento durante el giro. Según la revisión de Sabnavis, en [10], los defectos se pueden clasificar en dos categorías: según su geometría y según su comportamiento. Según su geometría pueden ser:

- Defectos perpendiculares a la dirección axial del eje, que son conocidos como defectos transversales. Éstos son los más comunes y más serios, ya que reducen la sección del eje y lo debilitan. La mayor parte de las investigaciones actuales están enfocadas a detectar este tipo de defectos.
- Defectos paralelos a la dirección axial del eje, que se conocen como defectos longitudinales.

- Defectos oblicuos, que forman un ángulo con la dirección axial del eje. Son muy poco comunes, y afectan al comportamiento torsional del eje.

Y por otra parte, según su comportamiento se clasifican en:

- Defectos que siempre permanecen abiertos, se conocen normalmente en la bibliografía como ‘notches’. A este tipo de defectos se dedica la mayor parte del trabajo experimental.
- Defectos que se abren cuando el material afectado se ve sometido a tensiones de tracción, y por tanto la rigidez se ve reducida, y que cuando las tensiones son de compresión, la fisura permanece cerrada y la rigidez es precisamente la del elemento intacto. Este fenómeno se conoce con el nombre de **respiro**. Según Sekhar et al. [12], las condiciones para que un eje respire es que gire lentamente bajo la única carga de su propio peso.

Es muy común en maquinaria rotativa encontrar grietas transversales en las que se observa el fenómeno de respiro. La mayoría de las investigaciones teóricas, por tanto, se dedican al estudio de grietas transversales que respiran.

Son muy numerosos los trabajos teóricos que proponen funciones de respiro para modelar la manera en la que la fisura se abre y se cierra, en función del ángulo de rotación (o de la velocidad de giro y el tiempo) [13]. La mayoría de los autores utilizan una función escalón en la que la fisura pasa de estar totalmente abierta a totalmente cerrada, según propuso Gash en [14], que se rige por la ecuación 2.1, donde α es el ángulo de giro, y tiene la forma que se muestra en la figura 2.1.

$$g(\alpha) = \begin{cases} 1, & \cos \alpha \geq 0 \\ 0, & \cos \alpha < 0 \end{cases} \quad (2.1)$$




Figura 2.1: Función de respiro propuesta por Gash

La razón de utilizar estas funciones abruptas es que la teoría de SERR, utilizada para calcular la flexibilidad local generada por el defecto, solamente es válida cuando la fisura está totalmente

abierta, y no se puede extrapolar a otros estados intermedios [15]. Sin embargo, otros autores utilizan funciones más suaves, en la mayoría de los casos trigonométricas, para simular la apertura y el cierre de la grieta, como es el caso de la función de Mayes y Davies [16], que se puede escribir según la ecuación 2.2, como puede observarse en la figura 2.2.

$$g(\alpha) = \frac{1 + \cos \alpha}{2} \quad (2.2)$$




Figura 2.2: Función de respiro propuesta por Mayes and Davies

En cuanto a la manera de caracterizar el tamaño de una fisura, el parámetro tradicionalmente utilizado es la profundidad relativa respecto al radio del eje [17]. Sin embargo, en publicaciones recientes, se propone el uso de la sección relativa afectada del eje respecto a la sección total. Este nuevo parámetro ha demostrado, según un estudio publicado en [3], que la respuesta de los ultrasonidos es invariante para valores iguales de este parámetro. Es decir, diferentes geometrías de grieta con la misma sección afectada del eje, generan la misma respuesta ante un ensayo de ultrasonidos. Por tanto, este parámetro permitiría independizar la respuesta de un defecto de su geometría.

Todos los resultados obtenidos de las diferentes teorías para modelar fisuras, (que principalmente vienen de la combinación de las teorías basadas en SERR con las funciones de respiro), han permitido cuantificar los cambios de rigidez debidos a la aparición de defectos. Los resultados obtenidos se han utilizado para simular fisuras en modelos de máquinas rotativas, como en el caso de algunos realizados en elementos finitos, como el de Kulesza en 2012 [18]. En el trabajo de Kumar de 2009 [19] se puede encontrar una revisión de algunas aproximaciones realizadas para estudiar la dinámica de rotores fisurados, sobre todo mediante la técnica de elementos finitos.

Sin embargo, el modelo de rotor más utilizado en los últimos años para conocer la respuesta dinámica de este tipo de máquinas, ha sido el rotor de Laval o también llamado rotor Jeffcott [20]. Este modelo consiste en una barra, flexible, uniforme, isotrópica y sin masa, considerada una viga biapoyada. En el centro de la misma se encuentra un disco de masa M . El modelo clásico de rotor Jeffcott se muestra en la figura 2.3, donde puede observarse un cierto desequilibrio entre el centro de rotación, y el punto de aplicación de la fuerza centrífuga.




Figura 2.3: Modelo de rotor Jeffcott

Las ecuaciones 2.3 y 2.4 [21], muestran las expresiones más comunes del modelo, tanto en la dirección x como en la y .

$$M\ddot{x} + c\dot{x} + kx = M\rho\omega^2 \cos(\varphi_0 + \omega t) \quad (2.3)$$

$$M\ddot{y} + c\dot{y} + ky = Mg + M\rho\omega^2 \sin(\varphi_0 + \omega t) \quad (2.4)$$

Donde M es la masa total del disco, c es el coeficiente de amortiguamiento del rotor, k es la rigidez del sistema, y ρ es la distancia que el centro del disco está desplazado de su eje. Las ecuaciones del modelo de rotor Jeffcott presentan un equilibrio de fuerzas planteado en el centro del disco, teniendo en cuenta las fuerzas debido al desequilibrio (que vienen representadas por el término $M\rho\omega^2 \cos(\varphi_0 + \omega t)$ en el caso de la ecuación en x y análogamente en la ecuación en y), las fuerzas amortiguadoras (representadas en la dirección x por los términos $c\dot{x}$ y $c\dot{y}$) y las fuerzas elásticas (kx y ky).

En [17] puede consultarse una amplia revisión de Gasch sobre variaciones del modelo de Jeffcott, funciones de respiro y su respuesta dinámica. También pueden consultarse trabajos más recientes sobre modelos analíticos de rotores fisurados en [22, 23, 13].

A pesar de los numerosos trabajos publicados analizando la respuesta dinámica de rotores fisurados, hoy en día, la detección de defectos en maquinaria rotativa sigue siendo una asignatura pendiente. Los trabajos relativos a técnicas de diagnosis son escasos, pero lo son mucho más los que presentan resultados experimentales. A continuación se presentan las técnicas de detección utilizadas en investigación en los últimos años.

2.1.2. Técnicas de detección de defectos en ejes

Hoy en día, el mantenimiento de ejes se realiza utilizando diferentes técnicas, según su ámbito de aplicación. Es común utilizar, como ya se ha mencionado, técnicas de inspección no destructiva (NDT) en algunos campos en los que las velocidades no son elevadas. Las investigaciones sobre la detección de fallos en ejes se centran fundamentalmente en NDT (se puede encontrar una revisión en [8]), y en técnicas basadas en el análisis de las vibraciones.

Sabnavis et al. publican en 2004 una revisión de las técnicas basadas en las vibraciones más utilizadas para la detección de defectos en ejes [10]. Aunque dicha revisión y clasificación trata sobre métodos basados en vibraciones, Sabnavis los clasifica como: métodos basados en el análisis

de vibraciones, análisis modal (cambios en modos propios y frecuencias propias), y métodos no tradicionales. El principal ámbito de aplicación de estas técnicas es la turbomaquinaria.

En el primer caso de **métodos basados en las vibraciones** (denominado así aunque los otros dos también están basados en las vibraciones) se incluyen tanto las técnicas en que las señales se obtienen de forma experimental como de forma analítica. En ellos la diagnosis se realiza teniendo en cuenta las conclusiones y los avances en las publicaciones relativas a la respuesta dinámica de rotores fisurados. De acuerdo con [12], cuando aparece un defecto en un eje, en su respuesta vibratoria no existe una velocidad crítica definida, sino una zona amplia con vibraciones violentas. Este fenómeno ha sido utilizado con éxito para la diagnosis de defectos, como en el caso de [24]. En la revisión de Gasch del 2008 [17] se señala que, estas inestabilidades no sólo aparecen en la velocidad crítica, sino también en ciertos subarmónicos de la misma, por lo que estas frecuencias se pueden considerar indicadores de defecto. El fenómeno es más importante cuanto mayor es la profundidad del defecto. Según trabajos como [25], el primer subarmónico de la velocidad crítica en el que este hecho se produce de forma significativa es el $1/4$, que es una velocidad admisible en turbomaquinaria, sin embargo hay muchos casos de maquinaria rotativa en los que no es posible alcanzar velocidades tan elevadas. Además, aunque en la teoría estos efectos son muy claros, en la práctica, la detección temprana de un defecto no es una tarea sencilla, y en trabajos como [26], las diagnosis basadas en estos fenómenos resultaban en una tasa de detección inferior al 25 %. Esta dificultad para trasladar los resultados teóricos a la realidad también se ha observado en otras frecuencias propuestas como indicadores de defecto, que consisten en armónicos de la velocidad de giro. Las grietas transversales respiran con una frecuencia igual a la rotación del eje. Las frecuencias que experimentan más cambios al aparecer un defecto son las componentes $1x$ y $2x$, (donde x es la velocidad de rotación del eje), en las que muchos autores afirman que se producen aumentos sustanciales de energía cuando aparece una fisura. Son pocos los trabajos en los que se menciona el armónico $3x$ como indicador de defecto, incluyéndose en ellos el de Sekhar de 2004[27]. En él, además, se afirma que las grietas longitudinales respiran con una frecuencia que depende, no sólo de la frecuencia de giro del eje como el caso de las transversales, sino además es función de la frecuencia de su vibración torsional. En [28] se señala el armónico $2x$ como el que sufre los cambios más significativos al aparecer un defecto. En otros trabajos como [25], se afirma sin embargo que los subarmónicos de la velocidad crítica son mejores indicadores que los armónicos de la velocidad de giro. Finalmente, no hay un consenso sobre qué componente es mejor indicador de defecto, y parece ser que depende de cada caso particular [10].

El segundo grupo en el que Sabnavis clasifica las técnicas de detección de ejes es el análisis modal, que es el más popular. Para examinar los cambios en los modos y frecuencias propias, como ya se explicó para el caso de elementos estructurales, se aplica una excitación específica en una zona y se observa la respuesta.

En cuanto a los métodos no tradicionales, en el trabajo de Sabnavis [10] se incluyen los métodos que utilizan sistemas de clasificación inteligente tales como redes neuronales artificiales (ANN, del inglés *Artificial Neural Networks*), lógica borrosa (FL, del inglés *Fuzzy logic*), y máquinas de soporte vectorial (SVM, del inglés *Support Vector Machines*). También se incluyen técnicas sofisticadas de procesamiento de señales, como por ejemplo, la transformada Wavelet (WT, del inglés *Wavelet Transform*) [29]. La mayoría de estas técnicas utilizan también señales vibratorias para realizar la diagnosis.

Papadopoulos en 2008 en [11] hace una revisión de las técnicas de detección de defectos en ejes más utilizadas hasta ese momento, aunque en este trabajo la clasificación de los métodos es distinta, y simplemente distingue entre métodos basados en vibraciones (los más comunes) y

métodos basados en modelos. Papadopoulos agrupa en primer lugar a todos los métodos basados en la medida directa de vibraciones, y que analizan cambios en la respuesta vibratoria y cambios en frecuencias y modos propios, utilizando métodos tradicionales y no tradicionales. En el segundo grupo considera los modelos que sitúan en el lugar de una grieta cargas equivalentes que producen los mismos efectos. Algunos métodos del segundo grupo se pueden consultar en [30, 31]. También existen trabajos en los que se combinan las técnicas basadas en vibraciones y en modelos, como en el caso del trabajo de Sekhar en 2004 [32].

Dentro de los métodos basados en el análisis de vibraciones, hay muchos modos de tratar las señales. Tradicionalmente se han utilizado técnicas basadas en el dominio de la frecuencia, como la transformada rápida de Fourier (FFT, del inglés *Fast Fourier Transform*) o la transformada de Fourier en tiempo corto (STFT, del inglés *Short Time Fourier Transform*), para detectar cambios en la respuesta vibratoria cuando aparece un defecto, como en el caso de [33]. Sin embargo en los últimos años las técnicas que Sabnavis clasificaba como no tradicionales han ido sustituyendo a las técnicas convencionales. La transformada de Fourier está siendo sustituida por herramientas matemáticas que proporcionan información tanto en el dominio del tiempo como en el de la frecuencia. Así, son numerosos los trabajos en los que se ha utilizado la transformada de Hilbert-Huang [19, 34], aunque la herramienta más utilizada en los últimos tiempos ha sido sin duda la WT. Trabajos recientes como el de Adewusi [35], Prabhakar et al. [36], Sekhar [37], Liu [38] o Nagaraju et al. [39] han demostrado la bondad de la transformada Wavelet aplicada a señales vibratorias para diagnosticar defectos en maquinaria rotativa.

La transformada Wavelet también ha sido utilizada con éxito para la diagnosis de ejes degradados utilizando señales de emisión acústica (AE, del inglés (*Acoustic Emission*)) durante el funcionamiento de la máquina, como en el caso de [40].

Por otra parte, es común la combinación de la WT con sistemas de clasificación inteligente para la diagnosis. Tales son los casos de trabajos como el de Sanz et al. [41] y Bin et al. [42], donde la WT es combinada con redes neuronales, el caso de Xiang et al. donde se incluye la utilización de algoritmos genéticos, y Hu et al. [43], donde se utiliza como sistema clasificador las llamadas máquinas de soporte vectorial (SVM, del inglés *Support Vector Machines*).

En la sección 4.3 se puede encontrar un estado del arte sobre la Transformada Wavelet.

2.2. Trabajos previos en defectología de rodamientos

Los rodamientos son elementos fundamentales en el soporte de una máquina, ya que sostienen gran parte de las cargas estáticas y dinámicas. Debido a esto son elementos con elevados riesgos de fallo. Las principales causas de defectos en rodamientos son la contaminación debido a la entrada de partículas externas o incluso agua, las excesivas vibraciones en la máquina, pasos de corriente, errores en el montaje o en el uso, etc. Estas causas pueden provocar defectos en el material por desgaste abrasivo, corrosión, deformación plástica, fatiga, e incluso se puede llegar al fallo total de los rodamientos debido a una fractura.

Hay muchos tipos diferentes de rodamientos, que generalmente están compuestos por un aro externo, un aro interno, y una jaula que encierra los elementos rodantes. Cada uno de los elementos estructurales que componen un rodamiento puede fallar, y mientras el rodamiento se encuentra en funcionamiento, el fallo excita unas frecuencias periódicas llamadas **frecuencias fundamentales de fallo**. Estas frecuencias provienen de los impactos que se producen cada vez que los elementos rodantes pasan sobre el elemento defectuoso. Los impactos pueden excitar resonancias en el rodamiento y en la máquina en general. Estas frecuencias son [44]:

- BPFI(del inglés *Ball Pass Frequency Inner Race*, frecuencia de paso de la bola por la pista interna):

$$BPFI(Hz) = F_s \frac{n}{2} (1 + \frac{d}{D} \cos \beta) \quad (2.5)$$

- BPFO(del inglés *Ball Pass Frequency Outer Race*, frecuencia de paso de la bola por la pista externa):

$$BPFO = F_s \frac{n}{2} (1 - \frac{d}{D} \cos \beta) \quad (2.6)$$

- BPFR(del inglés *Ball Pass Frequency Roller*, frecuencia de paso de la bola): es el doble de la frecuencia de giro de un elemento rodante BSF(*Ball Spin Frequency*, frecuencia característica de defecto en bola) ($2xBSF$).

$$BPFR = F_s \frac{D}{d} [1 - (\frac{d}{D} \cos \beta)^2] \quad (2.7)$$

- FTF(del inglés *Fundamental Train Frequency*, frecuencia característica de defecto en jaula) (estos defectos son muy poco comunes):

$$FTF = \frac{F_s}{2} (1 - \frac{d}{D} \cos \beta) \quad (2.8)$$

Donde F_s es la frecuencia de rotación del eje, n es el número de elementos rodantes, d es el diámetro de los elementos rodantes, β es el ángulo de contacto entre las pistas interna y externa, y D es la distancia entre los centros de dos elementos rodantes diametralmente opuestos (también llamado *pitch diameter*), según la disposición que se muestra en la figura 2.4.




Figura 2.4: Elementos y geometría de rodamientos

Las técnicas clásicas de detección de defectos en rodamientos se han basado tradicionalmente en la búsqueda de estas frecuencias excitadas por los defectos. Pero en la práctica, estos fenómenos pueden verse enmascarados por ruido y otros fenómenos indeseados, sobre todo en el

caso de defectos incipientes. Por ello, al igual que ha ocurrido en el caso de los ejes, las técnicas convencionales, como la FFT, se han ido sustituyendo por otras más avanzadas.

La mayoría de las investigaciones realizadas en el campo de la diagnosis de defectos en rodamientos coinciden en que el método más adecuado para la detección de defectos en rodamientos es el análisis de las señales vibratorias [45]. De todos los trabajos publicados en este ámbito, han surgido numerosas metodologías para el tratamiento de las señales vibratorias o extracción de patrones, que principalmente han sido clasificadas en tres aproximaciones: técnicas basadas en parámetros de la señal temporal, técnicas basadas en el análisis del dominio frecuencial, y técnicas que obtienen información tanto en el dominio del tiempo como en el de la frecuencia.

En cuanto a estudios de la señal vibratoria en el dominio del tiempo, en trabajos como [46, 47, 48] se señalan parámetros como la desviación estándar, la kurtosis, el coeficiente de asimetría y el factor de cresta como indicadores de defecto. Sin embargo, estos parámetros han mostrado ser poco efectivos cuando se aplican a fallos incipientes o cuando el sistema está expuesto a un bajo nivel de carga [49].

El análisis del dominio de la frecuencia es la aproximación más clásica para detectar fallos en rodamientos, y más concretamente el análisis de la envolvente. En la envolvente de señales obtenidas de rodamientos defectuosos, se observa que aparecen pequeños deslizamientos que hacen que la respuesta de este elemento no esté exactamente en fase con el eje. A este fenómeno se le denomina cicloestacionaridad de segundo orden (CS2), y es uno de los parámetros más usados como indicador de defectos en rodamientos [50]. Existen dos aproximaciones para obtener la envolvente de una señal que, de acuerdo con [51], son el método de rectificación-filtrado, y la transformada Hilbert (HT, del inglés *Hilbert Transform*). Aunque la HT presenta mejores resultados, esta técnica tiene una desventaja importante, y es que es extremadamente sensible al ruido, especialmente para defectos en fases incipientes. Debido a ello, en la actualidad se siguen realizando trabajos para mejorarla, como en el caso de [52]. En otros casos, para mejorar los resultados de diagnosis, el análisis de la envolvente ha sido combinado con otras técnicas, como por ejemplo, la transformada Wavelet, como en [53]. Otra técnica aplicada comúnmente para analizar el dominio de la frecuencia de las señales vibratorias es la llamada descomposición empírica en modos (EMD, del inglés *Empirical Mode Decomposition*). Esta herramienta se utiliza para obtener las funciones de modos intrínsecos (IMF, del inglés *Intrinsic Mode Functions*), como se muestra en el trabajo de [54].

En los últimos años, ha surgido otra técnica que ha ofrecido buenos resultados para rodamientos, como se puede consultar en [55]. Esta técnica es la llamada transformada de Hilbert-Huang (HHT, del inglés *Hilbert-Huang Transform*), que trabaja tanto en el dominio del tiempo como en el de la frecuencia. Con ella, se obtienen por un lado las IMF mediante EMD, y por otro lado, se obtienen las frecuencias instantáneas de la señal mediante un análisis espectral de la HT.

De la misma manera que para el caso de los ejes, la transformada Wavelet ha tomado mucho en los últimos años para diagnosis de rodamientos. Esta herramienta ha sido utilizada en numerosos trabajos, en los que también es combinada con sistemas de clasificación inteligente, como ANN en [56, 57, 58], FL en el caso de [59], o SVM en [43].

Capítulo 3

Metodología propuesta

El objetivo de este trabajo es desarrollar una metodología genérica para el diseño de una técnica de diagnóstico óptima, válida para un elemento mecánico rotativo perteneciente a una máquina particular. Se pretende realizar la diagnosis durante el funcionamiento de la máquina, a velocidades inferiores a la crítica, a partir de su respuesta vibratoria. El trabajo está fundamentalmente centrado en ejes, donde se ha realizado una exhaustiva investigación. Además, la metodología propuesta ha sido validada para el caso de rodamientos.

Para el estudio realizado, se distinguen de manera general dos fases fundamentales:

- Investigar las características dinámicas de la máquina en presencia de un defecto del tipo que se pretende diagnosticar, y seleccionar posibles patrones válidos o indicadores.
- Realizar diagnosis basadas en los patrones seleccionados, y definir para cada proceso las correspondiente curva POD y coste computacional, con el fin de seleccionar la técnica óptima para realizar el diagnóstico ‘online’.

3.1. Metodología general

La metodología general seguida en este trabajo parte de un **sistema mecánico** en el que se pretende diagnosticar el estado de un elemento concreto durante su funcionamiento. El primer paso es el **diseño de una metodología experimental** que permita una **adquisición de datos** representativa de las diferentes condiciones de defecto que se pretenden diferenciar. A continuación, y con base tanto en un **estudio teórico** como utilizando en el análisis de las propias señales obtenidas, se realiza la **extracción y selección de los posibles patrones válidos**, esto es, la selección de todos los parámetros que parecen cambiar cuando se modifican las condiciones que se pretenden diferenciar. Posteriormente, para cada posible patrón válido seleccionado, se lleva a cabo el **diseño de un sistema de clasificación** capaz de automatizar la decisión sobre el estado del elemento en cuestión. Finalmente, para cada patrón válido, se obtienen los resultados de clasificación, por lo que es posible seleccionar el método con el que se obtienen los mejores resultados. La metodología general está esquematizada en la figura 3.1.

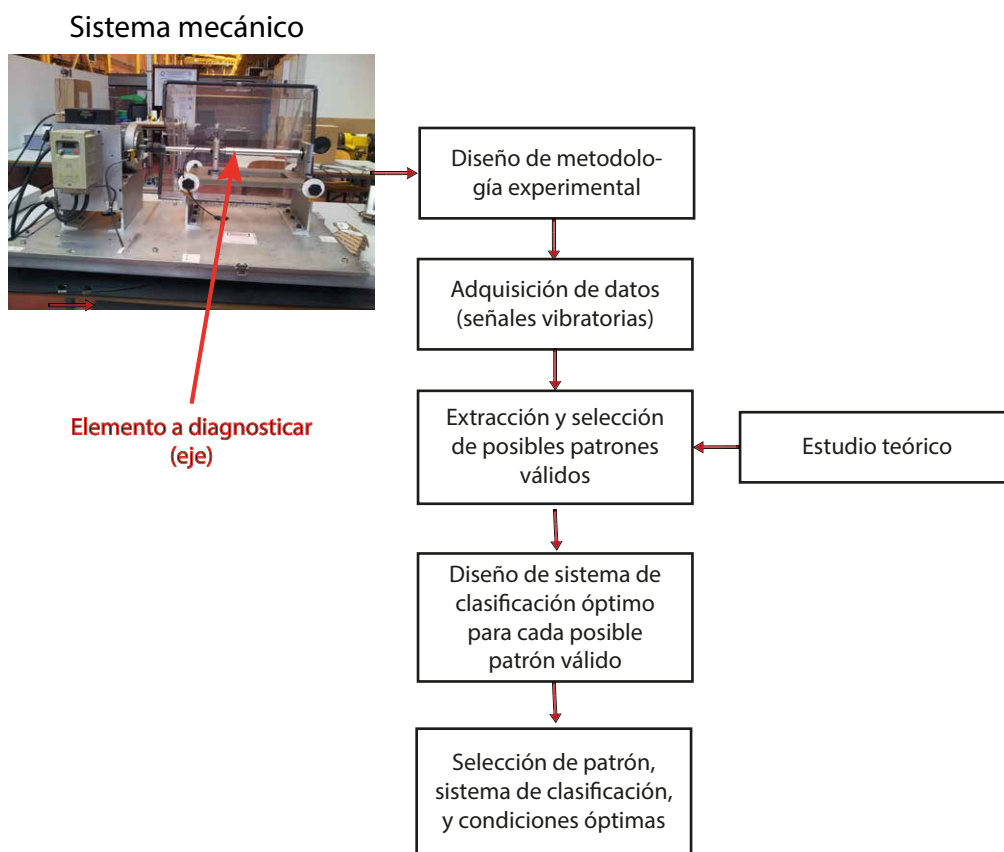


Figura 3.1: Esquema general de la metodología propuesta

La metodología termina en la **selección de los patrones, del sistema de clasificación y de las condiciones** que ofrecen la diagnosis óptima de un defecto en el elemento mecánico de estudio. La definición de estos parámetros, por tanto, permite el establecimiento de una técnica de diagnosis basada en el esquema de monitorización de estado que se mostraba en la sección 1.2 en la figura 1.1.

A continuación se pasará a detallar cada una de las fases.

3.2. Diseño de la metodología experimental y adquisición de datos

Partiendo del sistema mecánico, el primer paso es diseñar la metodología experimental para la adquisición de datos. Existen varios aspectos críticos como la selección de los sensores, la ubicación de los mismos y los parámetros de la señal muestreada. Para determinarlos será necesario realizar estudios previos de las respuestas que se obtienen. Además, será conveniente automatizar el proceso de adquisición en la medida que sea posible, con el fin de evitar errores.

Existe otro tipo de consideraciones fundamentales, como la selección de las condiciones de la máquina durante la adquisición de las medidas (velocidad, condiciones de carga, etc.). Éstas han de ser representativas del funcionamiento nominal, ya que es en este estado en el que se pretende

realizar la diagnosis. Si la máquina puede trabajar en condiciones variables, será conveniente establecer un rango de las mismas, para que sea posible discernir bajo qué condiciones se puede realizar la diagnosis óptima.

En cuanto a los defectos a estudiar, deberían ensayarse, al menos, aquellos que ocurran más frecuentemente, ya que éstos son los que interesa detectar. Será necesario definir la geometría de los defectos, así como su localización. Otra decisión fundamental es el rango de tamaños de defecto a investigar. Es interesante comenzar con tamaños muy pequeños para tener información sobre cuál es el menor que se puede detectar con fiabilidad. El tamaño más grande inspeccionado debe ser crítico, ya que también es determinante conocer cuál es el defecto más grande que sería posible no detectar. El número de intervalos inspeccionados es también crucial, ya que determinará la resolución de las curvas POD.

El número de medidas necesario para disponer de un grupo representativo de cada condición del eje debe ser estudiado a conciencia. Finalmente, para garantizar la repetibilidad de las medidas es muy recomendable realizar un protocolo que se cumpla fielmente en cada sesión.

La metodología de diseño de la metodología experimental está esquematizada en la figura 3.2.

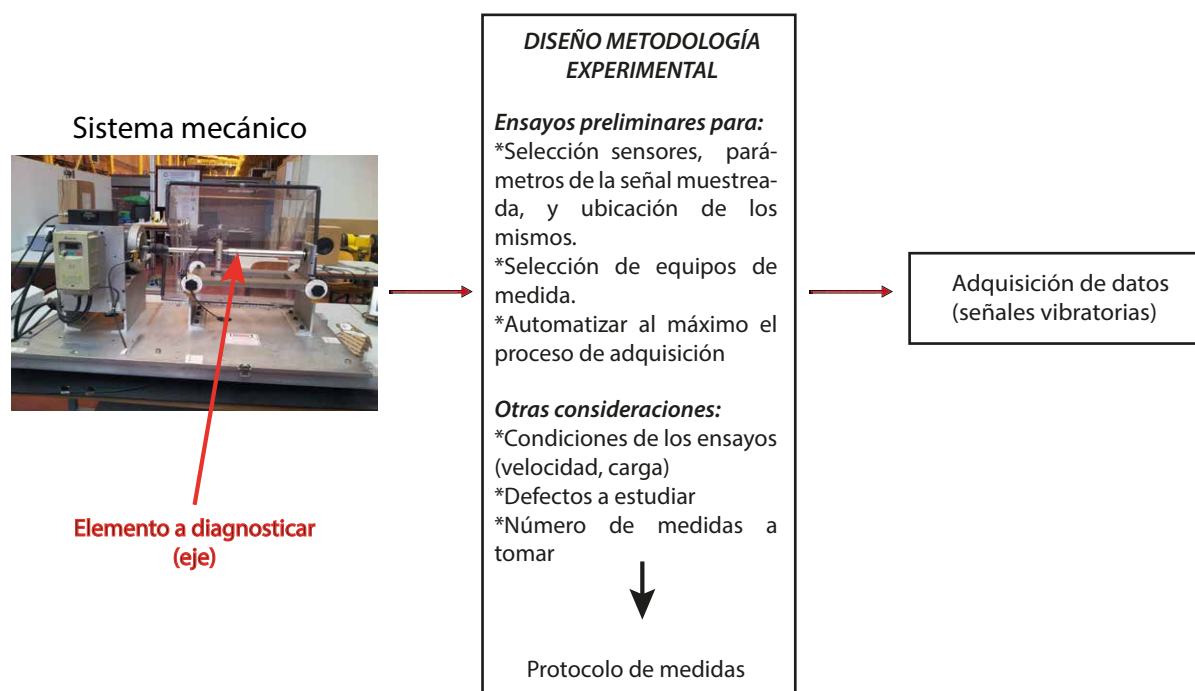


Figura 3.2: Metodología propuesta para la adquisición de señales a partir del sistema mecánico

3.3. Extracción y selección de posibles patrones válidos

Una vez realizada la adquisición de datos el siguiente paso es la extracción de patrones, así como la selección de aquellos que parecen indicadores de los defectos estudiados y por tanto son posibles patrones válidos para diagnosis de los mismos.

La extracción de patrones consiste en una transformación matemática de las señales para obtener determinados parámetros. Esto es necesario porque las señales vibratorias son poco manejables al estar compuestas por una elevada cantidad de datos. En defectología, dicha transformación ha de realizarse de tal manera que se conserve la información relativa al defecto que se quiere localizar, por lo que hay que seleccionar las herramientas adecuadas. Una vez aplicada la transformación elegida, hay que tener en cuenta, de forma cualitativa, dos aspectos fundamentales para llevar a cabo la selección de posibles patrones válidos:

- El patrón seleccionado debe contener información relativa al defecto: su información debe ser útil para hacer un diagnóstico fiable.
- El patrón seleccionado debe ser lo suficientemente sencillo y manejable como para diseñar un sistema de clasificación que discierna el estado del elemento con un coste computacional razonable.

Para llevar a cabo una selección de posibles patrones válidos, es fundamental el apoyo de un estudio bibliográfico de las técnicas comúnmente utilizadas para la diagnosis de defectos del elemento mecánico de estudio. Una vez realizado, se dispondrá de un abanico de herramientas matemáticas que se pueden utilizar. Hay que distinguir entre dos tipos de parámetros diferentes que se pueden obtener después de realizar las transformaciones:

- **Parámetros globales de la señal:** la herramienta matemática utilizada determina directamente un parámetro global de la señal obtenida, por ejemplo, los parámetros estadísticos. El cálculo de parámetros estadísticos utilizados típicamente para defectología, como la desviación estándar o la kurtosis, proveen información relativa a toda la señal medida con un único dato.
- **Parámetros locales de la señal:** la herramienta matemática utilizada provee un conjunto de datos complejo, por ejemplo, la transformada de Fourier o la transformada Wavelet. Cuando se utilizan transformaciones de este tipo, es necesario además definir las zonas de interés con las que se debe trabajar, es decir, los patrones locales a utilizar.

El esquema de la figura 3.3 muestra la metodología propuesta para la extracción y selección de posibles patrones válidos.

En primer lugar se ha de decidir, a partir de los estudios teóricos, qué herramientas matemáticas se van a tener en cuenta. A continuación, mediante estas herramientas, se transforman los datos obtenidos bajo diferentes condiciones de defecto. Para llevar a cabo la selección de posibles patrones válidos, se comparan los resultados obtenidos para las señales del elemento sano con los de los elementos defectuosos. En esta fase, se descartan aquellos parámetros que no presentan variaciones cuando aparece un defecto, es decir, aquellos que no contienen información relevante sobre el mismo. En el caso de herramientas matemáticas que ofrecen parámetros globales de la señal, este estudio es relativamente sencillo, ya que únicamente se atiende a un parámetro. Por el contrario, cuando la herramienta matemática ofrece como resultado un conjunto de parámetros locales, este estudio se complica, y es necesario realizar una selección de parámetros locales que sean posibles patrones válidos, proceso que se detallará en la siguiente sección.

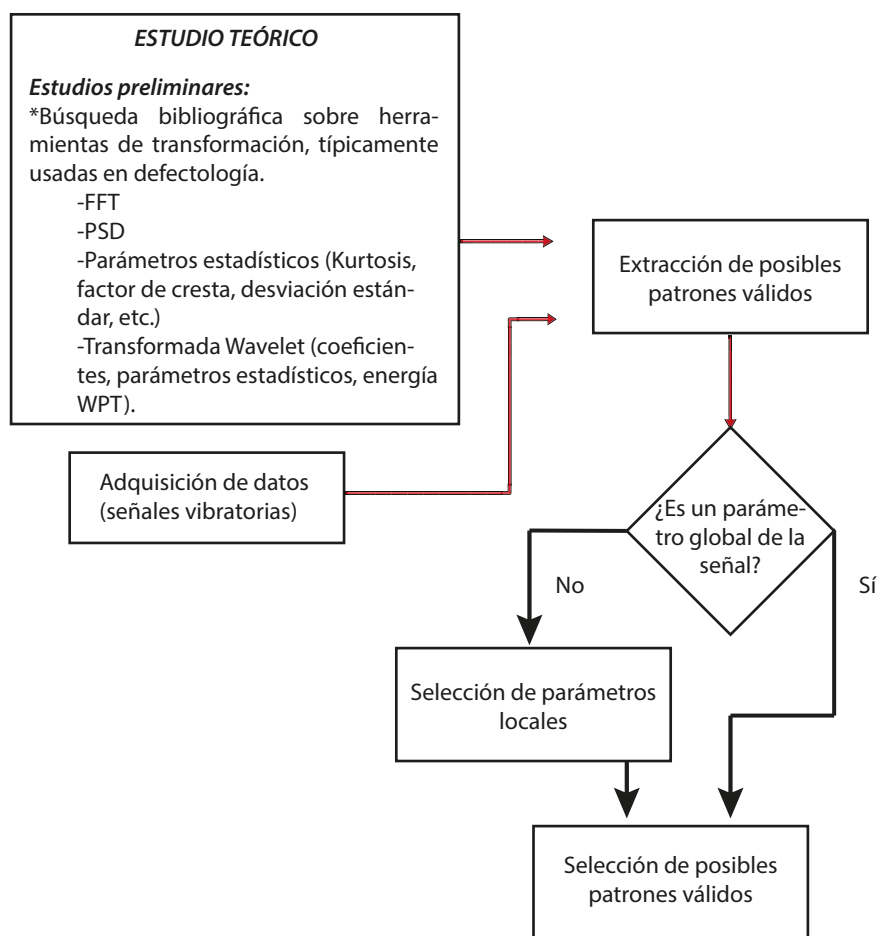


Figura 3.3: Metodología propuesta para la extracción de posibles patrones válidos

3.3.1. Selección de parámetros locales de la señal

En la presente Tesis Doctoral, se han utilizado fundamentalmente dos aproximaciones para llevar a cabo la selección de los parámetros locales de la señal; la primera de ellas está basada en estudios teóricos sobre las zonas de la señal sensibles a la aparición de defectos. La segunda aproximación está basada en el estudio de las propias señales adquiridas.

En cuanto a la primera aproximación, o estudio teórico de las zonas de la señal sensibles a la aparición de defectos, dichas zonas suelen ser estudiadas en el dominio de la frecuencia, por lo que en la bibliografía se suelen denominar frecuencias teóricas de fallo. Como se vio en el capítulo 2, para el caso de rodamientos estas frecuencias son bien conocidas, y experimentan un aumento de su amplitud cuando aparece un defecto. En el caso de ejes también existen varias frecuencias teóricas de fallo, como son los armónicos de la velocidad de giro o los subarmónicos de la velocidad crítica, que experimentan también aumentos en su energía. Sin embargo, no existe un consenso sobre cuál de ellos es mejor indicador, por lo que ha de ser estudiado en cada caso.

El estudio sobre las señales adquiridas se basa en la idea de que la aparición de un defecto en un elemento concreto de una máquina también afecta al funcionamiento del resto de elementos de la misma. La señal vibratoria obtenida contiene información relativa a la totalidad de la máquina, y es posible encontrar información sobre el defecto fuera de las frecuencias teóricas de fallo del

elemento concreto. Mediante esta segunda aproximación, por tanto, se buscarán las zonas en las que aparezcan mayores diferencias entre el elemento sano y defectuoso. En la figura 3.4 se puede observar la metodología realizada en este trabajo para la selección de los parámetros locales de la señal.

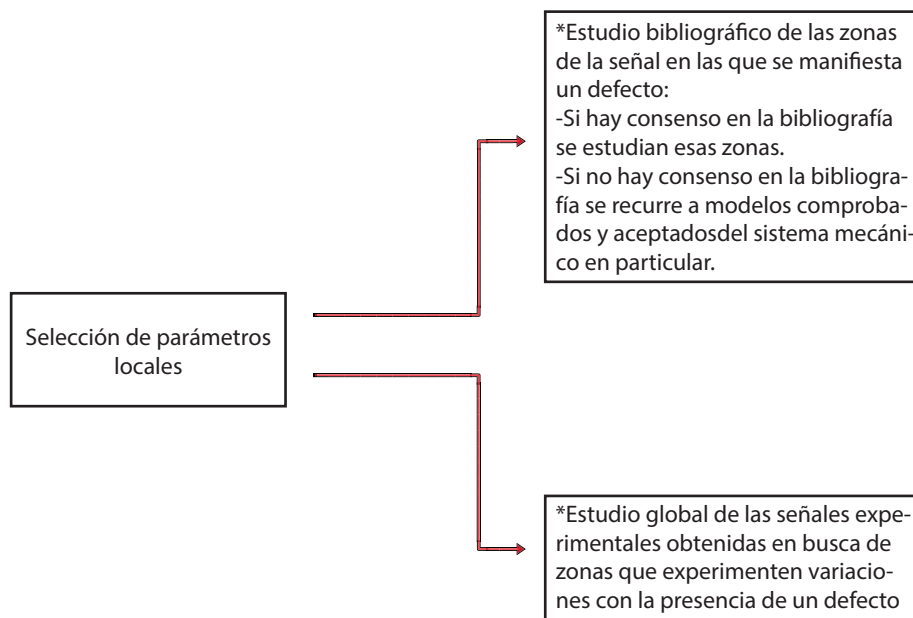


Figura 3.4: Metodología propuesta para la selección de parámetros locales, en los casos en que la herramienta matemática utilizada ofrece parámetros complejos

Entre las posibilidades analizadas se buscarán aquellos que presenten información relevante sobre el defecto, y se incluirán en la selección de posibles patrones válidos.

3.4. Diseño del sistema de clasificación

Una vez que se dispone varios posibles patrones válidos, es necesario seleccionar el óptimo. En la metodología propuesta, esta selección está directamente relacionada con los resultados del sistema de clasificación. Se propone, por tanto, el diseño de un sistema de clasificación óptimo para cada caso, que maximice las tasas de acierto del clasificador y minimice el coste computacional. Para hacer una selección previa sobre los posibles patrones válidos, en la sección 3.3 se hablaba de dos criterios que se habían de tener en cuenta (en ese punto de forma cualitativa): el primero de ellos era que el patrón contuviera información relativa al defecto, y el segundo de ellos el coste computacional. En este punto, esos dos criterios se pueden cuantificar y ser utilizados para la selección del método óptimo de diagnosis, que engloba tanto la decisión sobre los patrones como sobre el sistema de clasificación:

- La fiabilidad del método, que se medirá mediante curvas POD.
- El coste computacional requerido. Aunque el criterio de fiabilidad es fundamental, también es importante que el método no tenga un coste computacional excesivo. Dentro de aquellos

métodos que lo cumplan, se atenderá en primer lugar a la fiabilidad, y en caso de igualdad, la selección se realizará atendiendo a minimizar el coste computacional.

Para diseñar un sistema de clasificación que determine la condición del elemento mecánico a partir de los patrones seleccionados en el paso anterior, en el caso de patrones sencillos (por constar de pocos datos) se trabajará con el método de señal de respuesta. Este método es comúnmente utilizado en técnicas de inspección no destructiva, y consiste en la selección de un valor umbral que optimiza la separación de los datos de elemento sano y elemento defectuoso. Para realizar una diagnosis, se calcula el valor del patrón y en relación con el valor umbral, se decide si el elemento está sano o no. Posteriormente, basándose en técnicas estadísticas, se calculan los resultados de clasificación. Por otra parte, cuando se trata de patrones complejos (por componerse de un elevado número de datos), es conveniente recurrir a sistemas de clasificación inteligente. En este caso se trabajará con redes neuronales artificiales con arquitectura de función RBF, por ser la que ofrecía mejores resultados en un estudio previo [4].

Una vez diseñados el sistema de clasificación óptimo para cada posible patrón válido, se analizará la fiabilidad de cada método calculando las curvas POD. Atendiendo a los criterios ya mencionados, se escogerá tanto el patrón como el sistema clasificador óptimos. Una vez llegados a este punto, será posible discernir bajo qué condiciones de funcionamiento de la máquina se obtienen los resultados más favorables.

El esquema de la figura 3.5, muestra la metodología llevada a cabo para llevar a cabo esta selección.

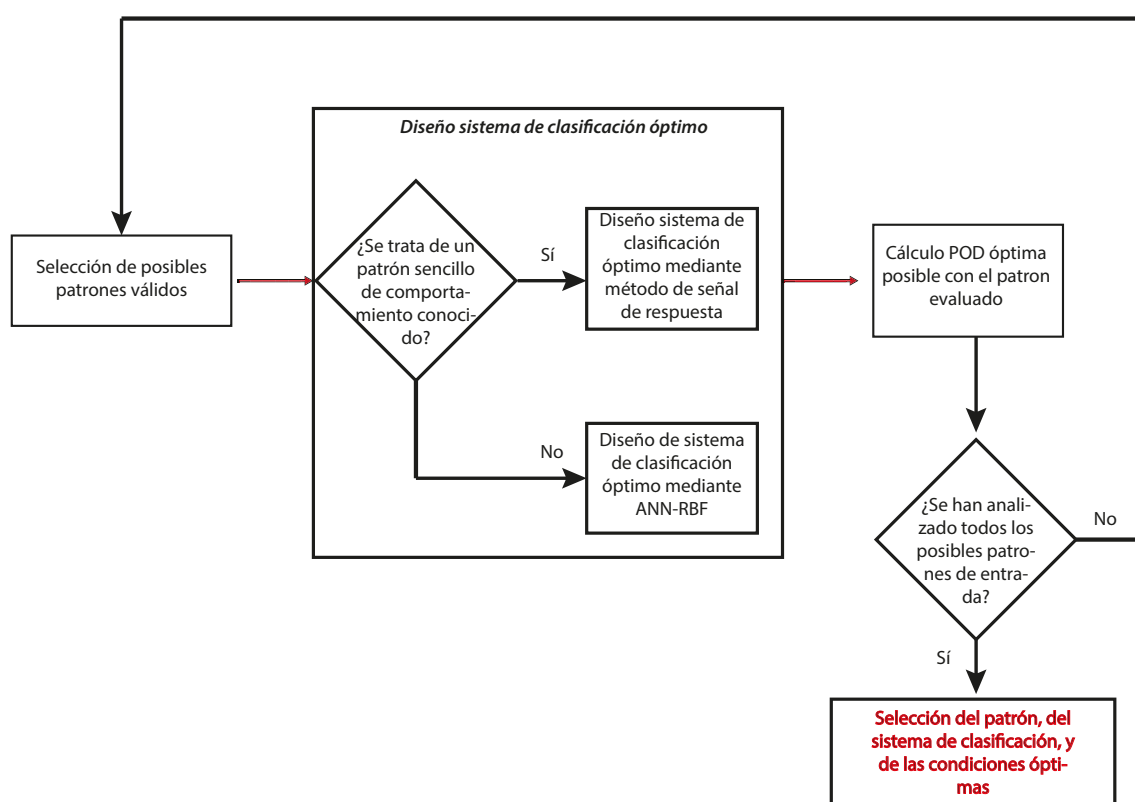


Figura 3.5: Metodología propuesta para la selección de patrones

En los capítulos siguientes se detallarán todos los procesos descritos de la metodología propuesta, y cómo han sido aplicados para el caso del diseño de una técnica de diagnosis óptima de defectos en el eje de un banco de ensayos llamado Rotokit.

Capítulo 4

Procesamiento de señales en defectología

En defectología, el procesamiento de señales vibratorias tiene como finalidad simplificar la información obtenida, manteniendo a su vez aquella que es relevante para discernir si hay presencia o no de un defecto, y de qué tipo es.

Las señales de vibración pueden clasificarse en:

- **Determinísticas:** son aquellas señales que representan fenómenos que pueden ser descritos analíticamente de manera exacta, es decir, su valor exacto se puede predecir. Se subdividen en dos grandes grupos:
 - **Periódicas:** son aquellas señales que repiten su comportamiento cada cierto intervalo de tiempo fijo.
 - **No periódicas:** se trata de señales que no repiten su comportamiento.
- **Aleatorias o estocásticas:** son señales que no es posible describir analíticamente con una expresión explícita simple como en el caso anterior. Por ejemplo, el ruido es una señal aleatoria. En este tipo de señales existe un mayor o menor grado de incertidumbre en cuanto a un valor instantáneo futuro. Sin embargo, durante un largo periodo de tiempo, en una señal aleatoria pueden observarse ciertas características de regularidad que permiten describirlas en términos estadísticos y probabilísticos. Las señales aleatorias se subdividen en dos grandes grupos:
 - **Estacionarias:** son aquellas en las que los parámetros estadísticos son constantes a lo largo del tiempo, es decir, las observaciones son esencialmente iguales independientemente del tiempo.
 - **No estacionarias:** son aquellas en las que los parámetros estadísticos no mantienen su valor a lo largo del tiempo.

Las señales vibratorias experimentales son medidas discretas obtenidas a una frecuencia de muestreo definida. Sea X una medida discreta de vibración, obtenida de un sistema real, con la siguiente forma:

$$X = [x(1), x(2), \dots, x(N)] = x(i) \quad (4.1)$$

Donde N es el número de muestras de la señal. N estará determinado por el tiempo total de adquisición de la señal T , y la frecuencia de muestreo de la misma f_s según la ecuación 4.2:

$$N = T \cdot f_s \quad (4.2)$$

Cada valor $x(i)$ del vector X , está tomado con intervalos constantes de tiempo Δt respecto a la muestra anterior según la ecuación 4.3:

$$\Delta t = \frac{T}{f_s} \quad (4.3)$$

En este capítulo se describirán las herramientas matemáticas utilizadas en la presente Tesis Doctoral para la transformación de las señales vibratorias obtenidas. La selección de estas herramientas está basada en el estudio bibliográfico del capítulo 2 sobre las técnicas utilizadas en defectología para ejes y rodamientos. En dicho capítulo se analizó que, en el caso de ejes, los estudios se han centrado fundamentalmente en la búsqueda de las frecuencias de fallo teóricas, basadas en herramientas que proporcionan información frecuencial, como la transformada rápida de Fourier, la transformada de Fourier de tiempo corto, y, en los últimos años, la WT. En el caso de rodamientos, donde las técnicas de diagnóstico están más avanzadas, las frecuencias teóricas de fallo son bien conocidas. Existe más variedad de técnicas para este tipo de elementos, y se han utilizado, además de las mencionadas anteriormente, el análisis de la envolvente, principalmente a través de la transformada Hilbert, así como parámetros estadísticos, como la kurtosis, la desviación estándar, el coeficiente de asimetría o el factor de cresta.

Los parámetros evaluados en la presente Tesis Doctoral como posibles patrones válidos, para el caso de defectología en ejes, son descritos a continuación clasificados según:

- Parámetros en el dominio del tiempo.
- Parámetros en el dominio de la frecuencia.
- Parámetros en el dominio del tiempo y frecuencia.

4.1. Parámetros basados en el dominio del tiempo

Los parámetros basados en el dominio del tiempo son, fundamentalmente, los que permiten revisar la estadística descriptiva de la señal. Además, se han añadido a este listado otros parámetros que, según la bibliografía, son buenos indicadores de defecto tanto para rodamientos y engranajes como para algunos elementos estructurales, como la kurtosis y el factor de cresta.

4.1.1. Medidas de centralización de la señal

- Media: la media es el más común de los parámetros descriptivos de tendencia central. Se define como el promedio aritmético de todos los datos de la muestra.

$$\mu = \frac{1}{N} \sum_{i=1}^N x(i) \quad (4.4)$$

- Mediana: es un valor tal que la mitad de las observaciones son menores que ese valor y la otra mitad mayores que el mismo. Su valor puede determinarse ordenando los datos de la muestra de menor a mayor y tomando el elemento central cuando exista (el elemento colocado en la posición $(n + 1)/2$ para n impar). Si no existe (n es par), conviene tomar como mediana el promedio de los dos elementos centrales.

4.1.2. Medidas de dispersión de la señal

- Desviación estándar: es un estadístico global definido como la raíz cuadrada del promedio de la suma de los cuadrados de la señal menos su media. Según [46] y [48], dicho parámetro varía con la presencia de defectos para engranajes y rodamientos. Es la raíz cuadrada de la varianza.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x(i) - \mu)^2} \quad (4.5)$$

4.1.3. Medidas relativas a la forma de la señal

- Coeficiente de asimetría o sesgo: es una medida de la asimetría de los datos. Si es positivo, los datos toman mayor extensión hacia la derecha de la media que a la izquierda. Si el coeficiente de asimetría es negativo sucede al revés. La asimetría de una distribución normal es cero.

$$S = \frac{\sum_{i=1}^N (x(i) - \mu)^3}{\sigma^3} \quad (4.6)$$

- Kurtosis: es una medida relacionada con la cantidad y la amplitud de picos presentes en la señal. Para una señal que posee ruido gaussiano, se espera un valor de 3. Cuando aumenta el número de picos o su amplitud, el estadístico tiende a crecer. Se espera que dicho parámetro varíe con la presencia de defectos para el caso de ejes, ya que según [46] y [48], ocurre para rodamientos y engranajes, y según [60], también ocurre para el caso elementos estructurales, siendo posible incluso detectar su posición y tamaño a través de este parámetro.

$$K = \frac{\sum_{i=1}^N (x(i) - \mu)^4}{\sigma^4} \quad (4.7)$$

4.1.4. Otros parámetros de interés

- Valor eficaz: es la raíz cuadrada del promedio de la suma de los cuadrados de la señal, o lo que es lo mismo, que es la raíz cuadrada del valor cuadrático medio o potencia media. También se denomina raíz cuadrática media (RMS, del inglés *Root Mean Square*).

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i)^2} \quad (4.8)$$

- Valor mínimo: es el valor mínimo de vibración.

$$X_{min} = \min(x(i)) \quad (4.9)$$

- Valor máximo: es el nivel máximo de vibración.

$$X_{max} = \max(x(i)) \quad (4.10)$$

- Valor de pico-pico: se define como la diferencia entre el valor máximo y el mínimo.

$$X_{pico-pico} = (\max(x(i)) - \min(x(i))) \quad (4.11)$$

- Valor de pico: el nivel de pico de la señal, se define como la mitad del valor de pico a pico de la señal.

$$X_{pico} = \frac{X_{pico-pico}}{2} \quad (4.12)$$

- Factor de forma: se define como el cociente entre el valor eficaz y el valor medio de la señal, con signo positivo.

$$FF = \frac{RMS}{\mu} \quad (4.13)$$

- Factor de cresta: es una medida, normalizada por el valor eficaz, de la amplitud de pico máximo. El factor de cresta es un indicador de los impactos que ocurren en la señal. El factor de cresta se incrementa con la presencia de pocos picos de gran amplitud causados por algunos tipos de daños localizados. Cuando aparece un valor por encima de 1,41 (el valor del factor de cresta para una señal sinusoidal perfecta) se considera que existe algún tipo de impacto. Se espera que dicho parámetro, varíe con la presencia de defectos en ejes, ya que junto con la kurtosis y la desviación típica, predicen defectos en otro tipo de elementos estructurales [46, 48].

$$CF = \frac{X_{pico}}{RMS} \quad (4.14)$$

4.2. Parámetros basados en el dominio de la frecuencia

Las técnicas basadas en el dominio de la frecuencia han sido utilizadas tradicionalmente para la detección de fallos. Este tipo de estudios se realiza examinando los picos de frecuencia en los que se modifica la amplitud, o aquellos que se ven desplazados con la presencia de un defecto.

Es sabido que la presencia de una grieta en un elemento estructural, reduce la rigidez del mismo, por lo que las frecuencias naturales se ven reducidas, y cambian los modos de vibración. El estudio de las frecuencias naturales ha sido siempre el primer paso para encontrar un indicador de daño en un elemento mecánico, ya que puede ser medido de forma fácil y rápida (incluso a través del método de elementos finitos) y está poco contaminado por ruido experimental [60]. La principal desventaja de esta técnica es que los cambios en las frecuencias naturales cuando aparece un defecto son muy pequeños, y pueden verse enmascarados debido a errores experimentales [61].

Por tanto, en maquinaria rotativa es común intentar localizar defectos a través de la respuesta dinámica del sistema. A continuación se exponen las técnicas más utilizadas en este campo.

4.2.1. Transformada rápida de Fourier

La transformada de Fourier (FT, del inglés *Fourier Transform*) $X(f)$ de una señal continua en el dominio del tiempo $x(t)$, se puede escribir como en la ecuación 4.15:

$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} dt \quad (4.15)$$

Esta transformada permite conocer las componentes en frecuencia de una señal mediante el cálculo de los coeficientes de correlación de la señal con distintas funciones sinusoidales [62]. Sin embargo, la existencia de sumatorios infinitos al calcular la transformada de Fourier de series temporales, hace necesaria la definición de una transformada adecuada para el procesamiento por ordenador de las señales discretas obtenidas de un sistema, como la transformada discreta de Fourier (DFT, del inglés *Discrete Fourier Transform*). Esta transformada permite obtener N componentes de frecuencia a partir de N componentes en el tiempo, a través de N^2 operaciones en el campo complejo. Mediante esta ecuación se obtiene la transformada $X(k)$ de la señal discreta $x(i)$ a partir de la ecuación 4.16.

$$X(k) = \sum_{i=0}^{i=N-1} x(i) \cdot e^{-j2\pi ki} \quad (4.16)$$

La transformada rápida de Fourier (FFT) es una herramienta matemática utilizada por los equipos de cálculo, que permite aplicar la DFT de forma eficiente reduciendo el número de operaciones de N^2 a $N \log_2 N$ [62]. Con la introducción del algoritmo de la FFT en los años 60 y el avance de los microprocesadores se consiguió un análisis más rápido y que el tratamiento de señales complejas, como las vibraciones, sea de uso común en la industria actual.

El tratamiento de señales mediante la FFT puede dar lugar a algunos errores que se detallarán a continuación, que son:

- Aliasing
- Ventana o ‘leakage’
- Empalizada o ‘Picket-Fence’

4.2.1.1. Aliasing

La FFT presenta una serie de limitaciones en el análisis debidas a la frecuencia de muestreo de la señal f_s . Esta frecuencia limita la frecuencia máxima hasta la cual se puede reconstruir la señal. Según el teorema de Nyquist [63] se cumple que $f_s \geq 2 \cdot f_{max}$, lo que quiere decir que la frecuencia de muestreo debe ser mayor o igual que el doble de la máxima frecuencia existente en la señal. Si en la señal existen frecuencias superiores a $f_s/2$, puede ocurrir que el espectrograma resultante difiera del real, como se observa en la imagen 4.1, donde aparece la reconstrucción errónea (rojo) de una señal (verde) muestreada por debajo de la frecuencia necesaria. Para evitar esto, es necesario aplicar un filtro denominado ‘antialiasing’, que elimina las frecuencias superiores a $f_s/2$, evitando posibles distorsiones.




Figura 4.1: Error en la FFT debido al ‘aliasing’

4.2.1.2. Ventana o leakage

Al utilizar la FFT, se asume que el registro de tiempo obtenido se repite periódicamente fuera del tiempo representado en él. Esto es cierto si la señal contenida contiene un número entero de ciclos, es decir, si la señal es periódica en el tiempo de registro. Sin embargo, si esto no es cierto se puede estar teniendo en cuenta una señal muy diferente a la original, tal y como se muestra en la figura 4.2.

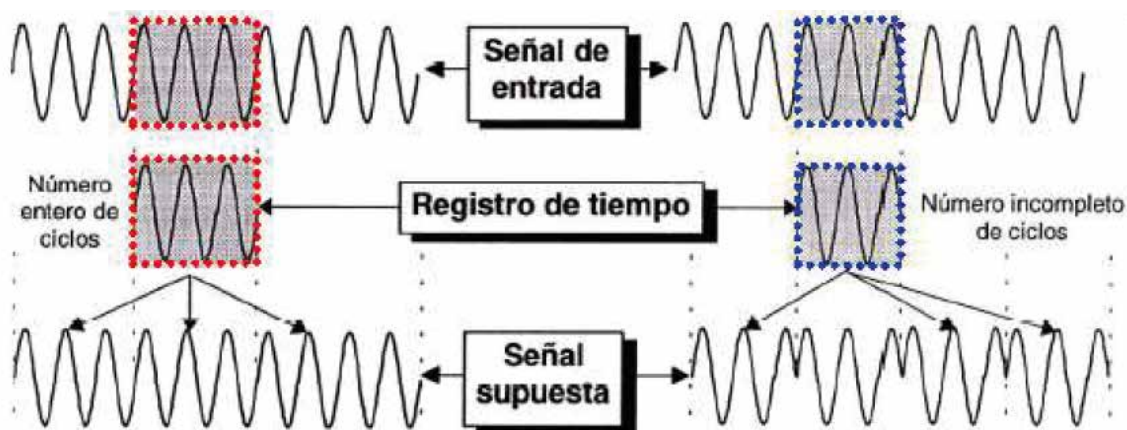


Figura 4.2: Error en la FFT debido la ventana temporal

Este efecto puede alterar en gran medida el resultado de la FFT. Este problema se puede solucionar utilizando una ventana espectral. Esto consiste en multiplicar la señal adquirida por

una ventana que reduzca la influencia de los extremos. Existen varios tipos de ventanas, sin embargo una de las más utilizadas es la Hanning. En la figura 4.3 se puede observar un ejemplo aplicando la ventana Hanning, cuyo valor en los extremos es cero.




Figura 4.3: Solución del error en la FFT debido a la ventana temporal

A la aplicación de la FFT con ayuda de estas ventanas se le denomina transformada de Fourier en tiempo corto (STFT). La aplicación de esta técnica permite tener resolución temporal, lo que hace a esta herramienta útil para el tratamiento de señales no estacionarias. Sin embargo, una de las limitaciones más fuertes de esta técnica es la dificultad para seleccionar correctamente el tiempo de aplicación de la ventana.

4.2.1.3. Empalizada o ‘Picket-Fence’

La FFT es un algoritmo para calcular de manera eficiente la DFT, y por lo tanto calcula el espectro a intervalos de frecuencia discretos. Por lo tanto, la amplitud y frecuencia real de las componentes puede perderse. El espacio entre las líneas de frecuencia (o resolución en frecuencia)

viene dado por la ecuación 4.17:

$$\Delta f = \frac{f_s}{N} \quad (4.17)$$

De manera que, si se desea mejorar la resolución en frecuencia (Δf), es necesario disminuir la frecuencia de muestreo (f_s) o bien aumentar el número de líneas de la señal (N).

4.2.2. Densidad de potencia espectral

Para el análisis frecuencial de una señal es común utilizar la densidad de potencia espectral (PSD, del inglés *Power Spectral Density*), que da idea de la cantidad de energía contenida en cada frecuencia. La potencia espectral de una señal discreta se puede expresar según la ecuación 4.18:

$$P = \frac{1}{T} \sum (x(i)^2 \Delta T) = \sum (S(k) \Delta f) \quad (4.18)$$

Donde la densidad espectral es el término denominado $S(f)$. Según la relación de Parseval [64], la energía de una señal E se puede calcular según las expresiones 4.19:

$$E = \sum (x(i)^2) = \frac{1}{N} \sum |X(k)|^2 \quad (4.19)$$

Por tanto, la densidad de potencia espectral $S(f)$ para cada frecuencia se podrá calcular según la ecuación 4.20:

$$S(f) = \frac{\Delta T}{N} |X(k)|^2 \quad (4.20)$$

4.2.3. Transformada Hilbert

La HT (*Hilbert Transform*, transformada Hilbert) presenta un estimado de la modulación de la amplitud presente en la señal, es decir, presenta un bosquejo de los eventos de baja frecuencia que modulan la señal original, también llamado envolvente. El análisis de la envolvente de una señal hace más sencilla la interpretación de la misma. Como se vio en la sección 2.2, existen dos aproximaciones para obtener la envolvente de una señal, y la más utilizada emplea la transformada de Hilbert, $\tilde{x}(t)$. Dicha transformada es la convolución de la señal $x(t)$ con $1/(\pi t)$, como se expresa en la ecuación 4.21:

$$\tilde{x}(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} x(u) \frac{1}{t-u} du \quad (4.21)$$

En defectología, se suele utilizar como patrón para algunos elementos la PSD de la transformada de Hilbert, lo que permite conocer las frecuencias que componen la envolvente de la señal. De esta manera, los eventos modulantes de baja frecuencia se amplifican, presentándose con mucha más energía que en el espectro de la señal original.

4.3. Parámetros en el dominio del tiempo y frecuencia. La transformada Wavelet

La transformada de Fourier y las técnicas derivadas de ésta (salvo la STFT) son inapropiadas para el tratamiento de señales no estacionarias, debido a la ausencia de información temporal. Como alternativa se presenta la transformada Wavelet (WT), que es un desarrollo matemático moderno para el tratamiento de señales que proporciona información tanto del dominio del tiempo como del de la frecuencia.

El uso de la herramienta matemática Wavelet comienza a popularizarse en el campo de la Ingeniería sobre todo a partir de finales de la década de los ochenta, cuando Stephane Mallat [65] descubrió algunas relaciones entre filtros espejo en cuadratura (QMF, del inglés *Quadrature Mirror Filters*), algoritmos piramidales, y bases ortonormales de funciones Wavelet. A partir de entonces, aparecen nuevas técnicas que permiten aplicar la transformada Wavelet a una señal mediante filtros recursivos. En los últimos años se ha convertido en la herramienta más utilizada para el procesamiento de señales en diferentes áreas. De esta manera, en los últimos años esta herramienta ha sido ampliamente utilizada en muchos campos como el reconocimiento de voz [66, 67], eliminación de ruido [68], y tratamiento de electrocardiogramas [69], entre otras.

Concretamente en el campo de la defectología ha sido aplicada en múltiples trabajos con éxito, sobre todo en el caso de ejes y rodamientos (como se analizó en el capítulo 2) pero también ha sido aplicada satisfactoriamente para detección de defectos en engranajes, en trabajos como [70, 71, 72], y en elementos estructurales, como en [73, 74, 5].

La WT es una herramienta recomendada para trabajar con señales de tipo no estacionario, cualidad que la hace especialmente indicada para defectología en máquinas, ya que cuando aparece una fisura en un elemento se generan efectos transitorios en la señal que no pueden ser detectados teniendo en cuenta solamente el dominio de la frecuencia [75, 76]. La utilización de la transformada Wavelet es compleja debido a las múltiples maneras en que se puede aplicar, y al elevado número de parámetros que es necesario definir para su uso.

De la misma manera que con la transformada de Fourier se obtienen los coeficientes de correlación de la señal estudiada con una senoide, con la transformada Wavelet se obtienen los coeficientes de correlación entre la señal y una función seleccionada denominada Wavelet madre, dependiendo del resultado de la escala y posición de esta función. Hay numerosos tipos de familias distintas de Wavelets madre [77], entre las que cabe destacar la Daubechies, Coiflet, Symlet, Morlet o Meyer. Algunos ejemplos de funciones Wavelet pertenecientes a estas familias se pueden observar en la figura 4.4.

La selección de la Wavelet madre debe hacerse teniendo en cuenta la aplicación. No existe una metodología estándar para seleccionar la Wavelet madre más adecuada para cada caso, por lo que se suele escoger la que ofrece mejores resultados después de realizar varios ensayos con las más representativas.

A continuación se exponen diferentes variaciones de esta herramienta matemática.

4.3.1. Transformada Wavelet continua

La transformada Wavelet continua (CWT, del inglés *Continuous Wavelet Transform*) permite analizar las señales a través de los coeficientes de correlación, en lugar de utilizar la señal entera.

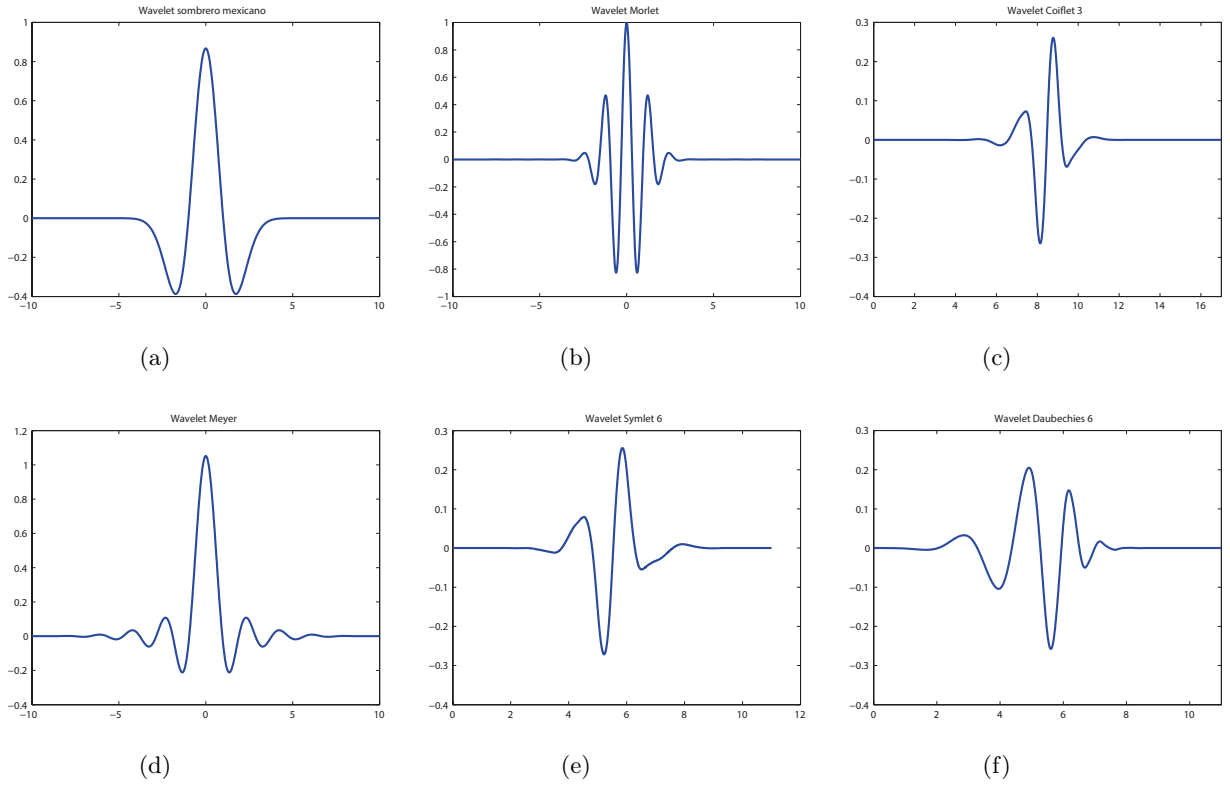


Figura 4.4: Familias de Wavelets más utilizadas como Wavelet madre (a) Wavelet Sombrero Mexicano (b) Wavelet Morlet (c) Wavelet Coiflet 3 (d) Wavelet Meyer (e) Wavelet Symlet 6 (f) Wavelet Daubechies 6

La formulación matemática de la CWT se muestra en la ecuación 4.22:

$$T(a, b) = w(a) \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (4.22)$$

Donde $x(t)$ es la señal temporal, ψ es la función Wavelet madre, y $w(a)$ es una función de pesos. Respecto a la Wavelet madre, b es el factor relativo a la posición y a a la escala. $T(a, b)$ son los coeficientes resultantes, que son función de a y b . El producto del conjugado de la Wavelet madre con la señal es integrado en el rango total de la señal. Esta operación se conoce matemáticamente como convolución [76]. En la figura 4.5 se puede observar una señal temporal y su CWT.




Figura 4.5: Señal temporal y su transformada Wavelet continua

4.3.2. Transformada Wavelet discreta

Las señales vibratorias son medidas discretas, por lo que partiendo de la definición de la transformada Wavelet continua, es habitual trabajar con la transformada Wavelet discreta (DWT, del inglés *Discrete Wavelet Transform*). Además, computacionalmente es más eficaz. Lo más común a la hora de discretizar la CWT es emplear la rejilla diádica como variable de escala, resultando $a = 2^k$. En este caso, la DWT viene dada por la ecuación 4.23.

$$T(2^k, b) = \frac{1}{2^k} \sum_0^N x(i) \psi^*\left(\frac{i-b}{2^k}\right) \quad (4.23)$$

Cada valor de k se denomina octava, y consiste en cada uno de los niveles en los que se descompone la señal (nivel de descomposición). Las escalas bajas tienen en cuenta las frecuencias bajas, y las escalas altas las frecuencias mayores.

Es habitual utilizar un procedimiento denominado diezmado. Este método consiste en descomponer la señal en un número de coeficientes proporcional a la escala analizada. Físicamente, refleja el hecho de que las frecuencias menores de una señal necesitan menos coeficientes para ser representadas.

Sin embargo, en las últimas décadas han aparecido variantes de la DWT que utilizan filtros digitales para optimizar el proceso de cálculo, generando información por bandas de frecuencia. Este avance, que permite un procesamiento más sencillo, ha hecho que la transformada Wavelet se popularice en el campo de la ingeniería. La herramienta, en este caso, consiste en procesar una señal temporal discreta $x(i)$ a diferentes posiciones y escalas (lo que significa diferentes frecuencias y niveles de resolución), descomponiendo la señal en información de aproximación (A) y detalle (D). La información de aproximación se obtiene mediante un filtro paso bajo, y la información de detalle mediante un filtro paso alto, tal y como se puede observar en la figura 4.6.




Figura 4.6: Descomposición de una señal (S) mediante DWT en información de aproximación (A) y detalle (D) mediante filtros

Después de aplicar los filtros, a una señal S con una banda de frecuencia $[0, \pi]$ y un número de muestras N , tanto la señal de aproximación (A) como la de detalle (D) contienen información en el dominio de la frecuencia relativa a la mitad de la señal original ($[0, \pi/2]$ y $[\pi/2, \pi]$ respectivamente). Por tanto y aplicando la regla de Nyquist [78], se justifica eliminar la mitad de las muestras sin pérdida de información relevante, resultando tanto la aproximación como el detalle con un número de muestras de $N/2$.

4.3.3. Análisis multiresolución

En las últimas décadas, la aplicación de las nuevas técnicas de filtrado para implementar la DWT ha derivado en otros métodos modernos para el análisis de señales. Un ejemplo de ellos es el análisis multirresolución (MRA, del inglés *Multiresolution Analysis*) que consiste en aplicar la DWT de forma recursiva hasta el nivel de descomposición deseado. La información se descompone en diferentes bandas de frecuencia, pero el principal inconveniente es que sólo es posible aplicarla sobre las señales de aproximación, como se muestra en la figura 4.7

4.3.4. Transformada en paquetes Wavelet

Debido a la incapacidad del análisis multirresolución para descomponer los niveles de frecuencia altos, la transformada en paquetes Wavelet (WPT, *Wavelet Packets Transform*) aparece para solventar este problema. Mediante la WPT toda la información, tanto de aproximación como de detalle, puede ser descompuesta hasta el nivel seleccionado: utilizando los mismos sistemas de medida y las mismas señales se puede obtener información relativa a frecuencias más altas que




Figura 4.7: Esquema del análisis multiresolución, procedimiento de descomposición hasta nivel 3




Figura 4.8: WPT análisis, procedimiento de descomposición hasta nivel 3

con el análisis multiresolución. Este proceso se puede observar en la figura 4.8.

El término $W(k, j)$ representa los coeficientes de un paquete, donde k es el nivel de descomposición (el número resultante de paquetes es 2^k) y j es la posición del paquete dentro del nivel de descomposición. Así, cada vector de correlación $W(k, j)$ tiene la estructura que se muestra en la ecuación 4.24:

$$W(k, j) = \{w_1(k, j), \dots, w_N(k, j)\} = \{w_i(k, j)\} \quad (4.24)$$

Esta técnica ha sido utilizada en los últimos años en defectología en maquinaria rotativa y monitorización de estado [42]. Los coeficientes WPT pueden ser directamente patrones para el diagnóstico de defectos, ya que contienen información fiable característica de los mismos, según [79]. Sin embargo, otro tipo información relativa a los coeficientes WT ha sido utilizada en otras ocasiones, como parámetros estadísticos [80], o la energía de la WPT, como en el caso de [81].

4.3.4.1. Contenidos de frecuencia en la WPT

El nivel de descomposición utilizado determina la resolución en frecuencia que ofrece cada paquete. Teniendo en cuenta la frecuencia hasta la que se puede reconstruir la señal, que en este caso se denomina π (la mitad de la frecuencia de muestreo según la regla de Nyquist), la banda

de frecuencias de cada paquete f_r viene dada por la ecuación 4.25:

$$f_r = \frac{\pi}{2^k} \quad (4.25)$$

A la hora de utilizar la descomposición WPT es fundamental entender cómo trabaja, ya que los paquetes resultantes no siguen el orden natural de frecuencias. Como ya se ha explicado, al descomponer una señal cuya banda de frecuencias es $[0, \pi]$, se obtiene una información de aproximación (A) relativa a la banda de frecuencias $[0, \pi/2]$, y una información de detalle (D), relacionada con la banda $[\pi/2, \pi]$. Las señales resultantes A y D son submuestreadas, reduciendo su número de puntos a la mitad. Sin embargo, para poder llevar a cabo el submuestreo de la señal de detalle D , por razones computacionales, ésta ha de ser transformada previamente mediante una simetría especular y trasladada al origen de coordenadas, de tal manera que el detalle resultante se encontraría en este caso en la banda de frecuencias $[0(\pi), \pi/2(\pi/2)]$. Este proceso se puede observar en la figura 4.9.

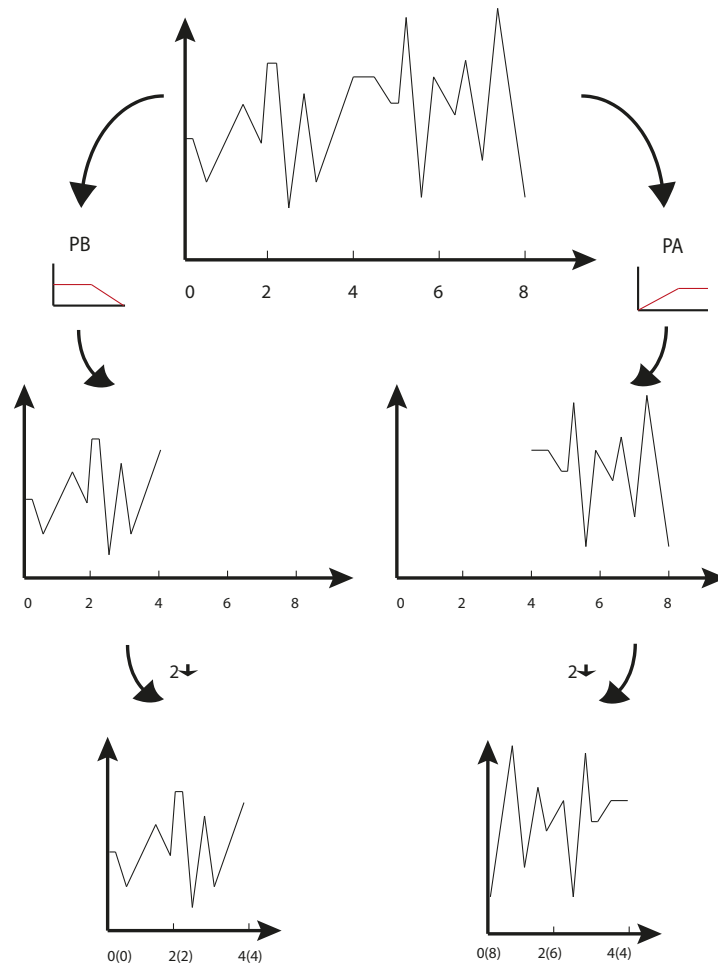


Figura 4.9: Señal de banda de frecuencia 8Hz descompuesta mediante WPT. La señal pasa por los filtros paso alto (PA) y paso bajo (PB) y se aplica una simetría especular al detalle a la hora de submuestrear ($2\downarrow$)

Cada vez que se descompone una señal de detalle, los dos paquetes generados aparecen intercambiados respecto al orden de frecuencia natural. Mediante la descomposición en los sucesivos niveles, los paquetes se desordenan progresivamente, como se puede observar en el ejemplo de la figura 4.10.

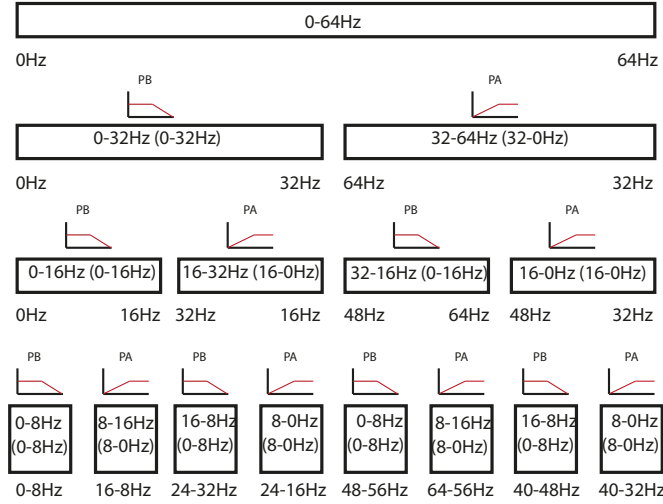


Figura 4.10: Orden de frecuencias obtenido para una señal de banda de frecuencia 64Hz descompuesta mediante WPT.

Se puede consultar con más detalle este fenómeno en [77].

4.3.4.2. La energía de la WPT

El concepto de energía utilizado en el análisis WPT está estrechamente ligado al de la teoría de Fourier [79]. La energía de un paquete j a nivel de descomposición k se obtiene mediante la suma de todos los cuadrados de sus coeficientes, de acuerdo a la ecuación 4.26.

$$E(k, j) = \sum_i \{w_i(k, j)\}^2 \quad (4.26)$$

Los valores de energía obtenidos son comúnmente normalizados respecto a la energía total de la señal, calculada como la suma de todas las energías de los paquetes, según se muestra en la ecuación 4.27.

$$E_t = \sum_j E(k, j) \quad (4.27)$$

Los valores de energía normalizados, por tanto, se pueden obtener mediante la ecuación 4.28.

$$E(k, j_{rel}) = \frac{E(k, j)}{E_t} \quad (4.28)$$

Esta normalización es tan frecuente que, dentro de las funciones preestablecidas en la toolbox de Wavelet de *Matlab*®, la que realiza el cálculo de las energías WPT (*wenergy.m*) incluye esta

normalización. Sin embargo, para los resultados de energía WPT de la presente Tesis Doctoral, esta función ha sido editada convenientemente para obtener los resultados sin normalizar de acuerdo con la ecuación 4.26, de forma que el valor de la energía de un paquete no dependa del valor de energía global de la señal. Se ha tomado esta consideración debido a que se va a trabajar con multitud de señales diferentes tomadas en diferentes instantes y, por tanto, en diferentes condiciones del entorno. Es probable que el contenido de energía total E_t , que es precisamente el parámetro de normalización sea diferente en cada señal. Si no se evitara esta normalización podría ocurrir que efectos indeseables, como ruido u otros fenómenos, perturbaran innecesariamente el valor de las frecuencias de interés.

En la figura 4.11 se puede observar un ejemplo energía WPT, obtenida de una señal vibratoria tomada desde el alojamiento de un rodamiento sano de una máquina girando a 10Hz, utilizando el nivel de descomposición 3.




Figura 4.11: Energías relativas de una señal obtenida mediante WPT a nivel 3

Capítulo 5

Sistemas de clasificación para diagnosis

En este trabajo se analizan varios patrones que, a priori, son indicadores de defecto en maquinaria rotativa. Con el fin de encontrar la técnica de detección óptima, es necesario cuantificar los resultados tanto de fiabilidad (mediante curvas POD) como de coste computacional que se obtendrían con cada uno de estos patrones, por lo que es necesario diseñar un sistema de clasificación adecuado para cada uno de ellos. En este trabajo se desarrollan dos sistemas clasificación distintos para su estudio y comparación:

- El método ‘ \hat{a} vs. a ’ o de ‘señal de respuesta’ (*signal-response*). Este método ha sido tradicionalmente utilizado para métodos de inspección no destructiva. Es adecuado utilizarlo cuando el patrón es simple y se puede establecer un valor umbral a partir del cual determinar que hay un defecto. En el método, \hat{a} representa la respuesta de la inspección y a el tamaño de la grieta.
- Redes neuronales artificiales ANN con arquitectura de función de base radial (RBF, del inglés *Radial Basis Function*). Se recurrirá a este tipo de sistemas de clasificación inteligente en el caso de que los patrones evaluados tengan una estructura compleja. La selección de esta arquitectura particular está determinada por trabajos previos de detección de defectos utilizando ANN [4].

5.1. Clasificación mediante el método ‘ \hat{a} vs. a ’

Para métodos de inspección no destructiva, concretamente ultrasonidos, se demostró en [82] que, cuando el tamaño del defecto aumenta, el valor de la señal de respuesta de la inspección se incrementa exponencialmente. Esto es equivalente a decir que entre el logaritmo de la respuesta de la inspección \hat{a} y el logaritmo del tamaño del defecto a hay una correlación del tipo:

$$\ln(\hat{a}) = \alpha + \beta \cdot \ln(a) + \gamma \quad (5.1)$$

El logaritmo de la respuesta frente al logaritmo del tamaño de defecto, por tanto, tiene tendencia a agruparse en torno a una recta de pendiente positiva β , y ordenada en el origen α . El término γ representa una distribución de error del tipo $N(0, \sigma_\gamma)$, (normal con media cero y desviación estándar constante σ_γ). De esta manera, y según la ecuación 5.1, $\ln(\hat{a})$ tiene una distribución normal según $N(\mu(a), \sigma_\gamma^2)$, (con media $\mu(a) = \alpha + \beta \cdot \ln(a)$ y desviación estándar σ_γ). De esto se deduce que la respuesta del método de inspección tiene una distribución log-

normal respecto al tamaño de defecto, es decir, su logaritmo se distribuye de forma normal, independientemente de la base del logaritmo [1, 3].

Para calcular el valor de las probabilidades de detección según este método es necesario establecer, en primer lugar, un valor umbral (\hat{a}_u) para la respuesta (\hat{a}) a partir del cual se considerará que hay un defecto, como se muestra en la figura 5.1. El valor umbral debe establecerse mediante prueba y error, buscando el valor óptimo que mejor separe los datos pertenecientes a elemento sano y defectuoso [1].




Figura 5.1: Valor umbral para el método de señal de respuesta

Así, la probabilidad de detección de un defecto de tamaño a , puede ser expresada de acuerdo a la ecuación 5.2:

$$POD(a) = Pr[\ln(\hat{a}) > \ln(\hat{a}_u)] \quad (5.2)$$

La probabilidad de detectar un defecto es la probabilidad de que el logaritmo neperiano de la respuesta obtenida sea mayor que el logaritmo del valor umbral seleccionado, suponiendo que dichos logaritmos se distribuyen de forma normal. Este tipo de probabilidades se pueden calcular mediante la llamada función de distribución acumulativa, $F(z)$, que se define como la probabilidad de que una variable tome valores menores o iguales al valor z . Por tanto, la probabilidad de detectar un defecto en este caso se podría calcular como $1 - F(z)$.

Para calcular el valor de $F(z)$ para una población normal, es necesario tipificar la variable, es decir, convertirla a distribución normal estándar (con media cero y desviación estándar uno, $N(0,1)$) ya que, para esta distribución, los valores de función de distribución acumulativa se pueden consultar en tablas. Esta tipificación se puede hacer según la ecuación 5.3:

$$Z = \frac{\ln(\hat{a}_u) - \mu(a)}{\sigma_\gamma} \quad (5.3)$$

Por tanto, es posible determinar la probabilidad de detección de una determinada técnica para un defecto de tamaño a y un valor umbral determinado \hat{a}_u , una vez conocidos los logaritmos de

los valores de la respuesta obtenida $\ln(\hat{a})$ (y por tanto su media $\mu(a)$ y su desviación estándar σ_γ) mediante la ecuación 5.4:

$$POD(a) = 1 - F\{z\} = 1 - F\left\{\frac{\ln(\hat{a}_u) - \mu(a)}{\sigma_\gamma}\right\} \quad (5.4)$$

Es fundamental conocer el comportamiento de cada técnica cuando la señal de respuesta corresponde a un elemento sano. La probabilidad de que la técnica acierte y no establezca una falsa alarma es, en este caso, la probabilidad de que las distribuciones de eje sano tomen un valor menor al umbral (precisamente el valor de la función de distribución acumulativa para el valor umbral $F(z)$), con lo cual, para el caso de tamaño de defecto 0, interesa que el valor de probabilidad sea lo más bajo posible.

En este trabajo se utilizará este método para los casos en los que los indicadores de defecto encontrados sean simples (por ejemplo, un valor de energía). En estos casos se tomará como hipótesis que el indicador de defecto aumenta de forma exponencial con el tamaño del mismo, al igual que ocurre con otros indicadores. Finalmente habrá que comprobar si la hipótesis es cierta.

5.2. Clasificación inteligente mediante redes neuronales artificiales

En la sección 7.2 se explicará la selección de posibles patrones óptimos a partir de las señales experimentales. Mediante esta aproximación, se encuentran múltiples paquetes de energía que parecen aumentar su energía de forma significativa con la aparición de un defecto, por lo que resultaría muy complejo realizar un sistema de clasificación para cada uno de ellos. Además, es lógico pensar que una combinación de varios de ellos pudiera proporcionar una diagnosis óptima.

En este tipo de casos en los que la búsqueda de un modelo o una solución exacta implica una cantidad de recursos extremadamente elevada, y en muchos casos imposible, se suele recurrir a los sistemas de clasificación inteligente.

A lo largo de la historia de la diagnosis de defectos en máquinas, se han desarrollado y utilizado distintos tipos de clasificadores inteligentes, de los que se puede consultar una revisión en [83]. Este campo, aunque se encuentra todavía en desarrollo a nivel de investigación, ha sido fundamental para los avances en la defectología. La evolución tuvo sus inicios en enfoques estadísticos clásicos de decisión (determinísticos y probabilísticos) [84], árboles de decisión [85], hasta otros que se han desarrollado recientemente a través de paquetes informáticos y que derivan de los anteriores, como la lógica borrosa (FL, del inglés *Fuzzy logic*) [86, 87], los algoritmos genéticos (GA, del inglés *Genetic Algorithms*) [88], máquinas de soporte vectorial (SVM, del inglés *Support Vector Machines*) [89, 90, 91] y redes neuronales artificiales (ANN, del inglés *Artificial Neural Network*), incluyendo versiones híbridas de todos los anteriores.

Uno de los más utilizados ha sido las redes neuronales, que cuentan también con una numerosa gama de aplicaciones. Concretamente para la diagnosis de rodamientos, las ANN han proporcionado mejores resultados que otros sistemas de clasificación inteligente aumentando las tasas de acierto, con cero falsas alarmas, menor número de errores al detectar defectos, y en mejores tiempos de ejecución, tal y como se señala en [92]. De esta manera, las redes neuronales se han aplicado en muchos trabajos a la diagnosis de rodamientos, como es el caso de [93, 53]. También han sido utilizadas para la detección de defectos en maquinaria rotativa como en [94, 95, 96], motores en [97, 98] y engranajes en [99], obteniendo muy buenos resultados en todos los casos.

El reconocimiento de patrones (PR, del inglés *Pattern Recognition*) es una actividad que el

cerebro humano realiza inconscientemente. El objetivo del desarrollo de los sistemas de clasificación inteligente, y concretamente de las ANN, consiste en identificar patrones de la misma manera que el cerebro humano, para poder clasificar muestras posteriores sin la necesidad de un operario experto. Las ANN son un ejemplo de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los humanos. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida.

En la figura 5.2 se puede observar el esquema de una neurona artificial básica.

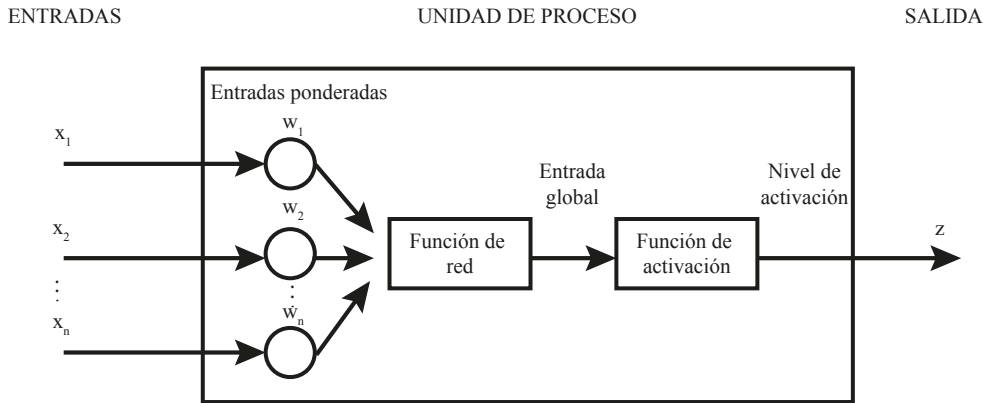


Figura 5.2: Esquema de neurona artificial básica

Las partes fundamentales de una unidad neuronal básica son:

- **Entrada:** es el vector x_i que excita a la neurona. Se compone de los patrones con que se desea entrenar la red durante el proceso de aprendizaje. Cuando la red esté en funcionamiento, serán los valores que se procesarán para su clasificación.
- **Pesos:** consiste en el vector de valores w_i con que se ponderan las conexiones entre neuronas. Estos valores se determinan durante el proceso de aprendizaje.
- **Función de red o de propagación:** esta función calcula el valor de la entrada global a la unidad neuronal (X). Resulta de la combinación de todas las entradas ponderadas junto con un valor umbral o bias (b). Las funciones más utilizadas son la lineal, que se muestra en la ecuación 5.5, y la de distancia, que puede escribirse como la ecuación 5.6.

- **Función de red lineal:**

$$X = \sum_{i=1}^n (w_i x_i + b_i) \quad (5.5)$$

- **Función de red de distancia:**

$$X = \sum_{i=1}^n \|x_i - w_i\| * b_i \quad (5.6)$$

- **Función de activación:** se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada global X . Las funciones de activación más populares en las diferentes arquitecturas son:

- Función escalón:


$$f(X) = \begin{cases} 1, & X \geq 0 \\ 0, & X < 0 \end{cases} \quad (5.7)$$



Es una función binaria, es decir, o se activa o no se activa.

- Función lineal:


$$f(X) = mX \quad (5.8)$$



Donde m es la pendiente. Estas funciones suelen tener convergencia inestable, ya que esta función no es normalizable y puede incrementarse sin límite.

- Función sigmoidal:


$$f(X) = \frac{1}{1+e^{-X}} \quad (5.9)$$



Donde los valores de la salida se normalizan entre 0 y 1.

- Función sigmoidal de tangente hiperbólica:

$$f(X) = \frac{e^X - e^{-X}}{e^X + e^{-X}} \quad (5.10)$$




Donde los valores de la salida se normalizan entre -1 y 1.

- RBF, *Radial Basis Function*):

- Función Gausiana:

$$f(X) = \exp\left[-\frac{\|X\|^2}{2\sigma^2}\right] \quad (5.11)$$



- Funciones multicuadráticas:

$$f(n) = \sqrt{\|n - c\|^2 + a^2} \quad (5.12)$$

- Multicuadráticas inversas:

$$f(n) = (\|n - c\|^2 + a^2)^{-1/2} \quad (5.13)$$

De las funciones de base radial, la gaussiana es la más ampliamente utilizada, aunque también se utilizan funciones multicuadráticas. Este tipo de funciones se caracterizan por ser extremadamente eficientes. Necesitan que el diseñador proporcione ciertos parámetros que afectan la magnitud del radio, como σ . Estas funciones de activación son simétricas: la salida es la misma para las entradas que están a la misma distancia del centro.

- Salida (z): es el valor de salida de la neurona en función de la activación de la misma. En el caso de la utilización de una ANN para el proceso de diagnóstico de fallos, la salida equivale al diagnóstico de la red.

Las neuronas se organizan por capas, donde se conectan a través de los pesos, tal y como se muestra en la figura 5.3. La arquitectura organizativa de una ANN está formada por una capa de entrada, una o más capas ocultas, y una de salida. Cada capa contiene un grupo de neuronas, cada una de las cuales envía su propia salida a los nodos de la siguiente capa.

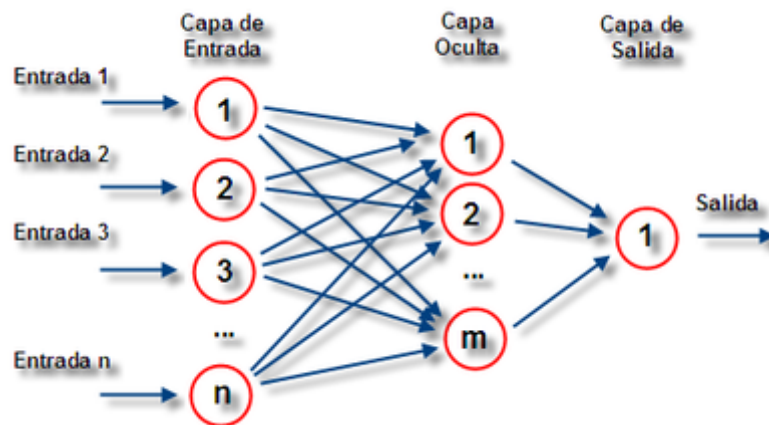


Figura 5.3: Esquema de red neuronal artificial básica

Hay diferentes arquitecturas de red, es decir, diferentes modos en los que interconexionan las capas de neuronas. Las más utilizadas en el campo de diagnosis de defectos son la perceptron multicapa (MLP, del inglés *Multilayer Perceptron*), la de función de base radial (RBF, del inglés *Radial Basis Function*), y la probabilística (PNN, del inglés *Probabilistic Neural Network*).

La arquitectura de las redes MLP se caracteriza porque cada neurona de salida está conectada a todas las de la capa anterior. Sin embargo, no existen conexiones entre neuronas de la misma capa. Las redes de tipo RBF muestran la misma configuración que las MLP, pero tienen una diferencia fundamental, y es que las neuronas de la capa oculta tienen carácter local, es decir, cada neurona de la red se activa en una región diferente del espacio de patrones de entrada. Este carácter local viene dado por el uso de funciones de base radial, siendo la más utilizada la gaussiana.

La figura 5.4 muestra la arquitectura de las redes MLP y RBF.




Figura 5.4: Comparación de arquitecturas de red neuronal comunes (a) Arquitectura de red MLP (b) Arquitectura de red RBF

Las redes de tipo PNN son una variante de las RBF, que han sido utilizadas también en diagnóstico de defectos [100], aunque en menor proporción que las anteriores. En este caso, el funcionamiento en la capa oculta es igual que en las RBF, sin embargo, en la capa de salida, se realiza un sumatorio de todas las contribuciones de la capa anterior, generándose un vector de probabilidades para cada clase. De esta manera, el valor de 1 será asignado a la neurona con mayor probabilidad (se activa esta neurona), y el de 0 para las demás.

Existen dos fases diferenciadas en la utilización de una ANN convencional:

- La fase de aprendizaje o entrenamiento, que puede ser de dos tipos:
 - Aprendizaje supervisado: en este tipo de aprendizaje se conoce la salida deseada para los datos de entrada proporcionados.
 - Aprendizaje no supervisado: los datos de la salida deseada no se proporcionan a la red, de manera que ésta determina las características significativas de los datos del conjunto de entrenamiento.
- La fase de prueba y/o utilización: el objetivo de esta fase es simplemente verificar el comportamiento de la red ante unos datos de entrada desconocidos, con los que no ha sido entrenada. Esta fase es la que mide el éxito de la red como modelo.

Durante la fase de entrenamiento de una red con aprendizaje supervisado, la red ajusta los valores tanto de los pesos w_i como del umbral o bias b hasta que el error disminuye a un valor admisible impuesto por el usuario. La manera en la que se produce este ajuste depende de la configuración de la red. Durante la fase de aprendizaje, la desviación entre la salida deseada y la obtenida se calcula como el error cuadrático medio (MSE, del inglés *Mean Squared Error*), cuya expresión se muestra en la ecuación 5.14:

$$MSE = \frac{1}{N} \sum_{k=1}^m \sum_{j=1}^N (s_k(j) - y_k(j))^2 \quad (5.14)$$

donde N es el número de datos de entrenamiento, m es el número de neuronas en la capa de salida, $s_i(j)$ es el valor objetivo de la i -ésima neurona de la capa de salida para el dato de entrenamiento j , e $y_i(j)$ es la predicción de la i -ésima neurona de la capa de salida para el dato de entrenamiento j .

En el presente trabajo se utiliza la arquitectura RBF, con aprendizaje supervisado y función de activación gaussiana, por ser una de las más utilizadas y con mejores resultados en defectología de elementos mecánicos, como se demuestra en trabajos como [4]. Además posee ventajas como la sencillez de su diseño, su bajo coste computacional, y los buenos resultados que ofrece. En la siguiente sección se describirá más detalladamente su funcionamiento, así como la metodología de diseño utilizada en este trabajo.

5.2.1. Redes con función de base radial

Las redes RBF fueron creadas con el objetivo principal de trabajar con aplicaciones en tiempo real, y constituyen una de las arquitecturas de red neuronal más utilizadas en diagnosis de defectos. Su uso ofrece múltiples ventajas como un entrenamiento rápido y un diseño sencillo, ya que el número de parámetros a definir es reducido, ya que principalmente son críticas la selección de la función de activación y el número de neuronas en cada capa.

Como ya se ha visto, la RBF más simple está compuesta por tres capas de neuronas: una de entrada, una oculta, y una de salida. La parte más importante del algoritmo de entrenamiento tiene lugar en la capa oculta. En este trabajo se utiliza como función de red la de distancia, de acuerdo a la ecuación 5.6, por lo que el vector de entradas ponderado X es la distancia que existe entre el vector de entradas proporcionado a la red \tilde{x}_i , y el vector de pesos \bar{w}_i .

La función de activación con la que se trabaja es la gaussiana. Así, la salida de la capa oculta será el resultado de pasar X por la función de activación gaussiana $f(X)$, expresada en la ecuación 5.11. En dicha ecuación, al término σ también se le denomina comúnmente *spread*, y es un factor del ancho de la gaussiana utilizada. Este parámetro debe ser definido por el diseñador de la red y además determina la distancia crítica entre la entrada y el vector de pesos para que la salida alcance un valor umbral determinado.

Durante el proceso de entrenamiento, el algoritmo actualiza el vector de pesos, con el fin de reducir el valor del error cuadrático medio (MSE en la ecuación 5.14). Este proceso iterativo se repite hasta que, o bien se alcanza el valor máximo permitido de MSE (comúnmente denominado *goal*), o bien se alcanza un número de neuronas en la capa oculta, que es determinado por el diseñador.

En el presente trabajo, todas las redes neuronales han sido desarrolladas utilizando la Toolbox de redes neuronales *Matlab*®.

A modo de resumen, en la tabla 5.1 se muestran los parámetros de diseño de una red neuronal RBF con aprendizaje supervisado, función de red de distancia, y función de activación gaussiana (del tipo que se pretenden en este trabajo).

Parámetro	Definición	
Spread	Factor del ancho de la función gaussiana	
goal	Error cuadrático medio (MSE)	Criterios de parada
n_{max}	Número máximo de neuronas en la capa oculta	

Tabla 5.1: Parámetros de diseño de las redes RBF en este trabajo

Después de realizar múltiples estudios previos, la metodología empleada para encontrar los parámetros que optimizan las tasas de acierto y el coste computacional de cada red sigue los siguientes pasos:

- Selección de los patrones de entrada, que determinan el número de neuronas en la capa de entrada.
- Selección del número de salidas, que determinan el número de neuronas en la capa de salida. En este trabajo el número de posibles salidas de las redes es de dos (sano-defectuoso), ya que esta disposición es la que mejores resultados ha ofrecido.
- Selección del valor del valor máximo de error MSE permitido (*goal*). Se comenzará para todos los casos por el valor de 0,2, ya que es un valor adecuado para obtener buenos resultados sin excederse en coste computacional. Una vez escogida la red óptima, se refinarán para ella los resultados utilizando un valor de *goal* más restrictivo, que será de 0,1.
- Selección del valor óptimo del factor del ancho de gaussiana (*spread*) para cada caso. Para ello se realiza un barrido por diferentes valores en el rango $[0,2-2]$, donde se espera encontrar el óptimo. Dicho valor óptimo es seleccionado atendiendo primordialmente a maximizar la tasa de acierto. En caso de valores parecidos se atenderá también al número de neuronas en la capa oculta, que es un indicador del coste computacional del entrenamiento.

En resumen, para optimizar los parámetros de diseño de una red, una vez definidos los patrones de entrada y de salida, se selecciona un valor máximo para el error MSE admisible (*goal*) y se realiza un barrido para diferentes valores de *spread* en el rango definido. En la figura 5.5 se puede observar un ejemplo de las gráficas examinadas en este trabajo para la selección del factor del ancho de gaussiana (*spread*) óptimo, que son la representación del número de neuronas en la capa oculta y de la tasa de acierto frente al valor de *spread*, respectivamente.




Figura 5.5: Gráficas para la selección del valor de *spread* óptimo (a) Número de neuronas en función del *spread* (b) Tasas de acierto obtenidas en función del *spread*

El ejemplo concreto de las figuras pertenece a una red con 32 neuronas en la capa de entrada, dos salidas posibles (sano y defectuoso) y un valor de *goal* de 0,2. En este caso, el valor de *spread* óptimo seleccionado sería de 0,4, ya que este valor ofrece las tasas de acierto máximas, y a la vez tiene un número bajo de neuronas en la capa oculta, minimizando el coste computacional.

Capítulo 6

Sistema experimental: banco de ensayos, diseño de la metodología experimental y adquisición de datos

Con el fin de probar la bondad de la metodología desarrollada en la presente Tesis Doctoral, se obtienen señales vibratorias de un banco de ensayos llamado Rotokit.

En este capítulo se expone el sistema experimental completo. Dicho sistema incluye la descripción del banco de ensayos, así como el diseño de la metodología experimental con todos sus parámetros, incluyendo la cadena de medida. La metodología experimental propuesta resulta en un protocolo de medidas, que se ha cumplido fielmente para llevar a cabo la adquisición de datos.

6.1. Banco de ensayos

El banco de ensayos utilizado es una máquina de simulación de fallos desarrollada por la empresa *SpectraQuest*[®] [101]. Su objetivo principal es estudiar el comportamiento de elementos rotativos reales o escalados. El banco de ensayos se puede observar en la figura 6.1.

El banco de ensayos está formado por un motor *Marathon*[®], de velocidad máxima de 10.000r.p.m y potencia de 0,75KW, que conduce al eje mediante un acoplamiento elástico. La velocidad del motor se fija mediante un regulador *Delta*[®], modelo S1, y además, para evitar errores, se controla por medio de un tacómetro óptico marca *Banner*[®].

El eje se soporta mediante dos rodamientos de la marca *Rexnord*[®], modelo ER10. Éstos a su vez se apoyan en unas pletinas de aluminio.

El elemento de ensayo consiste en un eje de aluminio, cuyas dimensiones se pueden observar en la figura 6.2.

Las propiedades del mismo han sido determinadas experimentalmente y se muestran en la tabla 6.1.

A partir de dichas propiedades, se obtiene la velocidad crítica, en hercios, mediante la expresión mostrada en la ecuación 6.1

$$w_c = \frac{1}{2\pi} \sqrt{\frac{k}{M}} = 321,7Hz \quad (6.1)$$



Figura 6.1: Banco de ensayos Rotokit para la toma de medidas experimentales

Masa (M) (kg)	0,378
Coeeficiente de amortiguamiento (c) (kg/s)	4,58
Rigidez (k) (KN/m)	1544,3
Rho (ρ) (m)	2e-5
Longitud efectiva(m)	0,26
Diámetro (m)	0,0207

Tabla 6.1: Propiedades del eje utilizadas tanto para el modelo teórico como para el sistema experimental

6.2. Diseño de la metodología experimental

6.2.1. Ensayos preliminares: selección de sensores y parámetros de la señal

Antes de tomar decisiones sobre parámetros críticos del sistema de medida para la adquisición de señales, es necesario realizar una serie de pruebas.

Se dispone inicialmente de tres acelerómetros de distintos tipos, de entre los cuales se pretende seleccionar el más adecuado. Las principales características de cada uno de ellos se encuentran en la tabla 6.2.

Las hojas de características de los sensores se encuentran en la sección A.

Las diferencias fundamentales entre ellos son, por un lado la frecuencia de muestreo máxima




Figura 6.2: Plano del eje de aluminio ensayado en Rotokit

	Acelerómetro 1	Acelerómetro 2	Acelerómetro 3
Modelo	B&K 4383	B&K 4321V	B&K 4374
Tipo de acelerómetro	Aplicación general	Triaxial	Miniatura
Número de serie	2211105	2305399	30484
Peso	17 gramos	55 gramos	0,65 gramos
Sensibilidad	3,172pC/ms ⁻²	$x \rightarrow 0,983\text{pC/ms}^{-2}$ $y \rightarrow 0,983\text{pC/ms}^{-2}$ $z \rightarrow 0,975\text{pC/ms}^{-2}$	0,124pC/ms ⁻²
Resonancia	26,2KHz	$x \rightarrow 37,8\text{KHz}$ $y \rightarrow 36,6\text{KHz}$ $z \rightarrow 40,4\text{KHz}$	85KHz
Rango de frecuencia	0,1Hz a 8,4KHz	$x \rightarrow 0,1\text{Hz a } 12\text{KHz}$ $y \rightarrow 0,1 \text{ a } 12\text{KHz}$ $z \rightarrow 0,1 \text{ a } 12\text{KHz}$	1Hz a 26KHz
Rango de aceleración	$\pm 5.000\text{g}$ de pico	$\pm 1.000\text{g}$ de pico	$\pm 25.000\text{g}$ de pico

Tabla 6.2: Propiedades de los acelerómetros utilizados en este trabajo

que se podría utilizar con ellos, y por otro lado, las direcciones de medida. El acelerómetro 1 permite una frecuencia de muestreo mayor que los otros dos (26KHz). Los acelerómetros 1 y 3 son uniaxiales, mientras que el acelerómetro 2 es triaxial.

Se realiza una primera prueba con el acelerómetro 1, utilizando una frecuencia de muestreo de 20KHz. En la figura 6.3, se puede observar la PSD calculada utilizando una ventana de Hanning de una señal obtenida de un eje que gira a 20Hz, donde se observa que la información más significativa de la señal se encuentra entre los 500Hz y los 2,5KHz. Esto permite descartar el uso del acelerómetro 1, ya que no es necesaria una frecuencia de muestreo tan elevada.




Figura 6.3: PSD (V^2/Hz) con ventana Hanning de una señal temporal obtenida con el acelerómetro 1 a una frecuencia de muestreo de 20KHz

Realizando pruebas con el acelerómetro 2, no se aprecian grandes diferencias entre los parámetros obtenidos en las tres direcciones de medida. Aunque haría falta un estudio más exhaustivo, por razones de simplicidad, se decide realizar las medidas en una única dirección, la vertical, ya que en caso contrario habría que repetir toda la metodología propuesta tres veces, una para cada las medidas tomadas en las diferentes direcciones. Por esta razón, el acelerómetro seleccionado finalmente es el acelerómetro 3.

A la vista de la figura 6.3, y sabiendo que el rango admisible para la frecuencia de muestreo para el acelerómetro 3 es $[0,1-8,4\text{KHz}]$, se selecciona como frecuencia de muestreo 6.000Hz. Por el teorema de Nyquist [63], es posible reconstruir la señal hasta los 3KHz, y se considera que por encima de esta frecuencia no hay información significativa de la señal, por lo que se fijará mediante el acondicionador de señal un filtro paso bajo (antialiasing) de 3KHz. Para eliminar la información relativa a la componente continua, además, se realizará un filtrado paso alto a 0,1Hz.

Para seleccionar el número de puntos que definen cada señal, hay que analizar la velocidad de

giro de los ensayos y la frecuencia de muestreo, para asegurar que se mida un número significativo de ciclos de la máquina en cada adquisición. Considerando la velocidad más lenta, de 20Hz o 1.200r.p.m., se realizan 20 ciclos de la máquina cada segundo. En este trabajo se considera suficiente la adquisición de cincuenta ciclos de la máquina en cada señal, lo que implicaría un tiempo aproximado de 2,5 segundos por señal.

Además, debido a las técnicas computacionales existentes hoy en día, se recomienda que el tamaño de la muestra sea potencia de dos. En caso contrario, se produce el fenómeno de *zero padding* [102], es decir, que la señal se completa artificialmente con ceros hasta que su tamaño alcanza el de la siguiente potencia de dos, lo que introduciría errores. Esto se hace para reducir el coste computacional de las transformaciones.

Por todo ello y, teniendo en cuenta que la frecuencia de muestreo es de 6.000Hz, el tamaño total de la muestra seleccionado es de 16.384 puntos (2^{14}), es decir, la potencia de dos más cercana a los requisitos buscados. Este valor implica que cada señal se adquiere en un tiempo total de 2,73s.

De esta manera, al realizar una transformación al dominio de la frecuencia mediante FFT, la resolución en frecuencia del resultado sería de 6.2:

$$\Delta f = \frac{F_s}{N} = \frac{6000}{16384} = 0,36Hz \quad (6.2)$$

Es decir, se tendría un valor de frecuencia cada 0,36Hz, lo que se considera suficiente.

Por último se realizaron una serie de pruebas para definir la ubicación del sensor. Adquiriendo medidas en varias posiciones diferentes, se analizó sobre todo el nivel de ruido observado en la señal, y la claridad con la que se observaba la frecuencia de giro. La posición final escogida para el sensor fue la del alojamiento del rodamiento, donde el acelerómetro es fijado al tornillo de sujeción de la pletina de aluminio mediante un imán. La posición del acelerómetro se ha mantenido durante todos los ensayos.

6.2.2. Cadena de medida

A continuación del acelerómetro, en la cadena de medida, se dispone un acondicionador de señal NEXUS, de la marca Brüel and Kjaer, y una tarjeta de adquisición KUSB-3100 marca Keithley. El esquema de la cadena de medida se puede observar en la figura 6.4.

El acondicionador de señal realiza funciones tanto de amplificación como de filtrado para que la señal tenga las características adecuadas para su adquisición. Del acondicionador de señal, las medidas pasan a la tarjeta de adquisición, que se conecta mediante USB a un ordenador que archiva las medidas mediante un software realizado específicamente para este propósito llamado Btool [103], realizado en *Matlab*[®]. Este software permite realizar la adquisición de un número definido de medidas de forma automática, esperando entre una adquisición y otra un tiempo determinado también por el usuario. Los parámetros de las señales adquiridas se definen mediante la frecuencia de muestro y el número de puntos que contiene cada una.

6.2.3. Condiciones de los ensayos

El eje gira bajo la única carga de su peso, sin añadir carga externa. Se decide realizar la adquisición de las medidas durante el estado estacionario, que se considera un estado más representativo del funcionamiento de la máquina que un arranque o parada.

Los ensayos se realizarán a tres velocidades de rotación diferentes, representativas del funcionamiento nominal de la máquina, que son:

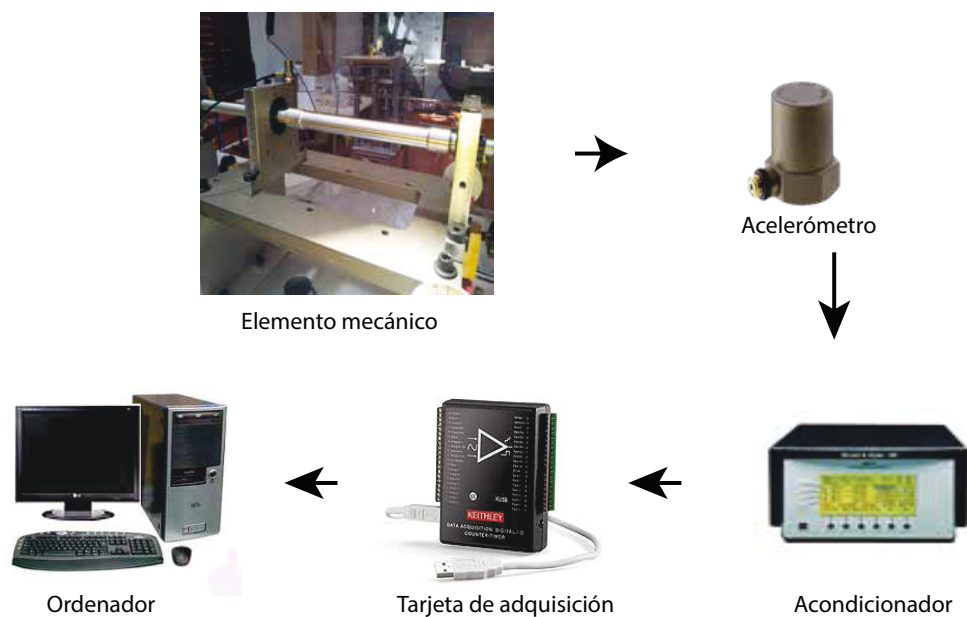


Figura 6.4: Cadena de medida

- 20Hz (1.200 r.p.m.)
- 40Hz (2.400 r.p.m.)
- 60Hz (3.600 r.p.m.)

Los datos obtenidos a cada velocidad de giro se tratan de forma independiente con el fin de analizar al final la influencia de la velocidad en los resultados de diagnóstico. Las velocidades de ensayo son bastante inferiores a la primera velocidad crítica del eje, que tenía el valor de 321,7Hz.

6.2.4. Defectos a estudiar

En este trabajo se consideran siempre defectos transversales superficiales, por ser los más comunes y más críticos. La localización del defecto para todos los casos es la posición central del eje.

En una primera aproximación y, por concordancia con trabajos previos realizados en ejes, a priori se tomó la decisión de generar 4 niveles de defecto que se correspondían con:

- Eje sano.
- Eje fisurado con una profundidad del 12,5 % respecto de su diámetro.
- Eje fisurado con una profundidad del 25 % respecto de su diámetro.
- Eje fisurado con una profundidad del 50 % respecto de su diámetro.

La metodología desarrollada en este trabajo se llevó a cabo con éxito utilizando ensayos con cuatro ejes diferentes. Durante estos ensayos se consiguió depurar la metodología experimental

relativa con las medidas obtenidas a estos niveles de defecto, obteniendo altas probabilidades de detección para todos los niveles evaluados. Es por ello que se decidió, en adelante, aumentar el número de niveles de defecto desde cuatro hasta nueve para aumentar la resolución de las curvas POD.

En cuanto al rango de tamaños utilizado, no se consideró necesario aumentar el tamaño máximo de defecto, ya que se considera suficientemente crítico. Sin embargo, el valor de tamaño mínimo sí que se vio reducido con el fin de obtener información sobre el tamaño de defecto más pequeño que es posible detectar con cada técnica estudiada.

Los nueve niveles resultaron:

- Eje sano (Es).
- Defecto 1 (D1): eje fisurado con una profundidad de 4,15 % respecto su diámetro.
- Defecto 2 (D2): eje fisurado con una profundidad de 8,30 % respecto su diámetro.
- Defecto 3 (D3): eje fisurado con una profundidad de 12,50 % respecto su diámetro.
- Defecto 4 (D4): eje fisurado con una profundidad de 16,65 % respecto su diámetro.
- Defecto 5 (D5): eje fisurado con una profundidad de 22,15 % respecto su diámetro.
- Defecto 6 (D6): eje fisurado con una profundidad de 25,00 % respecto su diámetro.
- Defecto 7 (D7): eje fisurado con una profundidad de 33,25 % respecto su diámetro.
- Defecto 8 (D8): eje fisurado con una profundidad de 41,65 % respecto su diámetro.
- Defecto 9 (D9): eje fisurado con una profundidad de 50,00 % respecto su diámetro.

La profundidad de los defectos fue el parámetro escogido para definirlos de cara a la generación de los mismos. Sin embargo, de acuerdo con [3], el parámetro más adecuado para definir las dimensiones de un defecto es el porcentaje de sección del eje al que afecta, ya que de esta manera la respuesta es independiente de la geometría del defecto. Por ello todos los defectos fueron generados mediante corte de sierra sin anteder a su geometría. Como el eje considerado tiene una sección de aproximadamente $338,81\text{mm}^2$, los datos de tamaño de defectos convertidos a porcentaje de sección afectada se corresponden con:

- Eje sano (Es).
- Defecto 1 (D1): eje fisurado con un área de 1,36 % respecto su sección.
- Defecto 2 (D2): eje fisurado con un área de 4,16 % respecto su sección.
- Defecto 3 (D3): eje fisurado con un área de 7,31 % respecto su sección.
- Defecto 4 (D4): eje fisurado con un área de 10,95 % respecto su sección.
- Defecto 5 (D5): eje fisurado con un área de 17,09 % respecto su sección.
- Defecto 6 (D6): eje fisurado con un área de 22,68 % respecto su sección.
- Defecto 7 (D7): eje fisurado con un área de 29,20 % respecto su sección.

- Defecto 8 (D8): eje fisurado con un área de 39,80 % respecto su sección.
- Defecto 9 (D9): eje fisurado con un área de 50,00 % respecto su sección.

En la figura 6.5 se puede observar un defecto de tipo D1 generado sobre el eje.



Figura 6.5: Defecto generado en un espécimen

6.2.5. Número de medidas a tomar

Una cuestión importante es qué número de medidas de vibración es necesario obtener de cada condición del eje estudiada para que quede convenientemente representada. Según el teorema central del límite [104], la suma de N variables aleatorias independientes de varianza finita e idéntica distribución tiende a la distribución normal cuando N es grande. Por tanto, y suponiendo una distribución normal, se podría estimar el error aleatorio E_r que se comete al calcular la media global a través de N datos de un patrón para un espécimen. Este error se puede calcular según la ecuación 6.3 [102].

$$E_r = \sqrt{\frac{2}{N}} \quad (6.3)$$

En este trabajo, se considera admisible obtener como mínimo un total de 1.600 medidas diferentes para cada eje y cada condición de estudio, lo que implicaría un error aleatorio del 3,5 % en cada espécimen. Para el caso particular de la condición de eje sano, se decide disponer como mínimo de 5.000 medidas (un número mayor por ser la referencia de la comparación), con lo que en este caso se cometería un error del 2 % en cada eje.

En este trabajo, las medidas de vibración de cada condición se toman consecutivamente en grupos de 100. Cada uno de estos grupos de medidas se toman de forma dispersa en el tiempo hasta completar las 1.600 para cada caso de defecto y velocidad (un total de 16 grupos para cada caso), y las 5.000 en el caso de eje sano (un total de 50 grupos). Estos grupos de 100 medidas consecutivas se toman con el fin de ser que sean promediadas ya que, al ser tomadas consecutivamente, se encuentran bajo las mismas condiciones ambientales. Este promediado permite reducir el número de datos, que es muy elevado y dificulta el análisis en muchos casos, como cuando se pretenden seleccionar los posibles patrones óptimos. Además, este promediado sirve para eliminar factores aleatorios o puntuales que puedan afectar a las medidas obtenidas, ya que el sistema experimental no está aislado y puede verse afectado tanto por ruido como por

vibraciones externas ajenas a la máquina. Mediante el promediado, tanto los aspectos no periódicos como el ruido tenderán a cancelarse. Al no sincronizar el inicio de todas las medidas, para que tengan lugar siempre desde la misma posición angular del eje, es necesario tener en cuenta que no se puede hacer un promediado directo de las señales temporales comúnmente utilizado, denominado promediado sincrónico en el tiempo, (TSA, del inglés *Time Synchronous Average*) [105]. Por esta razón, el promediado (no sincrónico), habrá de realizarse una vez que se haya eliminado la información temporal, es decir, después de la extracción de patrones. En el caso de que no pueda eliminarse la información temporal, este promediado no podrá llevarse a cabo.

6.3. Protocolo de medidas

Antes de realizar adquisición, la cadena de medida fue calibrada utilizando un calibrador de vibraciones. Posteriormente, se realizó un protocolo de medidas que fuera cumplido fielmente en cada sesión de medida con el fin de garantizar la repetibilidad de los datos y reducir la posibilidad de que existan errores.

Las fases principales del protocolo de medidas son:

- Comprobar el correcto montaje de la maquinaria, así como del eje y de las condiciones en las que se van a realizar los ensayos.
- Comprobar las conexiones de la cadena de medida. Comprobar además que los cables no están en movimiento, y que no existe contacto entre ellos y posibles fuentes de ruido.
- Poner a funcionar la máquina en las condiciones de velocidad previstas para los ensayos.
- Para cada una de estas condiciones, fijar los parámetros definidos para la adquisición de señales y realizar la adquisición.

Los parámetros para la adquisición de señales son definidos en el software Btool, como se muestra en la figura 6.6.

El protocolo de medidas completo y detallado se puede consultar en el apéndice B.

The image shows two overlapping windows from the Btool software. The left window, titled 'Seleccionar Ciclos', contains a section 'Configuración del Número de Ciclos' with input fields for 'Ciclos' (set to 100), 'Tiempo entre ciclos [s]' (set to 1), and 'Ciclo número:' (a black box). Below these is an 'Aceptar' button. At the bottom of this window is an 'Opciones' section with buttons for 'Almacenar datos', 'Manual', 'Automático', 'Osciloscopio', 'Micrófono', and 'Salvar y Salir'. The right window, titled 'Configuración tarjeta', has a 'Seleccionar Canal' section with checkboxes for 'Canal 1' through 'Canal 8', where 'Canal 1' is checked. Below this is a 'Configurar Parámetros' section with fields for 'Sample Rate [Hz]' (6000), 'Timer Period [s]' (10), 'Samples Per Trigger' (16384), 'Samples Acquired Fcn Count' (4096), 'Buffering Config' (10000 and 10), and 'Número de Ciclos' (Ciclos). At the bottom of this window are 'Aceptar' and 'Auto' buttons.

Figura 6.6: Parámetros definidos en la herramienta Btool para la adquisición de datos

6.4. Adquisición de datos: base de datos generada

Para la realización de este trabajo se cuenta con una base de datos compuesta en total de seis ejes ensayados. Los cuatro primeros ejes fueron ensayados con cuatro niveles de defecto. El grueso de la metodología propuesta en este trabajo fue desarrollada y validada a lo largo del estudio de estos cuatro primeros ejes. Posteriormente se ensayó un quinto eje del que, por motivos técnicos, no se pudieron obtener datos de algunos niveles de defectos, aunque los datos obtenidos sirvieron para avanzar en la metodología. Finalmente, se obtuvieron medidas completas de un sexto eje utilizando los nueve niveles de defecto definidos, y sobre los cuales se pudo aplicar íntegramente la metodología propuesta.

Así, para el eje del que se muestran los resultados en el capítulo 7, ensayado con nueve niveles de defecto y tres velocidades diferentes, se dispone de alrededor de 60.000 medidas independientes como la que se muestra en la figura 6.7, correspondiente a la señal temporal de un eje sano a 20Hz. En la figura 6.8 se puede ver la representación de su FFT. Con esto, se puede observar la cantidad de información de que se dispone y lo complejo que es el estudio.

Para el caso de las figuras 6.7 y 6.8, el efecto de la ganancia del amplificador de la cadena de medida ha sido corregido. Para el resto de resultados de la presente Tesis Doctoral, no se corrige este efecto por no considerarse necesario, ya que lo que se busca son cambios en la señal cuando aparece un defecto.




Figura 6.7: Señal temporal obtenida del sistema experimental para un eje sano




Figura 6.8: Transformada de Fourier de una señal temporal obtenida del sistema experimental para un eje sano

Capítulo 7

Desarrollo y resultados: aplicación de la metodología propuesta

Después de desarrollar la metodología presentada en el capítulo 3 durante el proceso de estudio y análisis de cuatro ejes diferentes, se procedió a realizar una nueva tanda de medidas sobre un nuevo espécimen utilizando el protocolo de medidas definitivo. Los resultados que se presentan en esta sección son los relativos a las medidas de un eje ensayado con nueve niveles de defecto, bajo condiciones de funcionamiento nominal de la máquina y durante un proceso que sería representativo de una degradación natural del eje, ya que los defectos fueron generados sin desmontar el mismo.

Una vez adquiridas las señales vibratorias, el objetivo es seleccionar los patrones, sistema de clasificación, y condiciones de la máquina óptimas. Para ello el primer paso es la selección de posibles patrones válidos. En el capítulo 4 se detallaron todas las herramientas analizadas en este trabajo para la selección de los mismos. Después de realizar todas las transformaciones, el fin es descartar aquellos patrones que no sean válidos para la detección de defectos, por no contener información relevante sobre los mismos al no presentar cambios con su aparición y crecimiento.

En primer lugar se examinaron los parámetros en el dominio del tiempo. Los resultados de estos estudios se expusieron en [106]. En él se muestra que, utilizando los datos extraídos de dos ejes durante su estudio completo con cuatro niveles de defecto, parámetros como la desviación típica, la kurtosis y el factor de cresta tienen tendencia a aumentar con la presencia de un defecto. Utilizando estas variaciones, se podrían detectar defectos con una profundidad relativa del 50 % en el 80 % de los casos. Sin embargo, defectos con un tamaño del 25 %, sólo serían detectados en aproximadamente el 60 % de las ocasiones. Esta fiabilidad no se considera suficiente, por lo que estos parámetros fueron descartados.

Posteriormente, se recurrió al análisis de parámetros en el dominio de la frecuencia. Los resultados obtenidos se pueden presentar en [107]. Aunque observando las gráficas PSD (utilizando ventanas de Hanning) se encuentran zonas del espectro en las que las amplitudes tienden a aumentar cuando aparece un defecto, no se observa una repetibilidad suficiente como para tenerlas en cuenta en una posible técnica de diagnóstico: la variabilidad es demasiado elevada. Mediante el análisis de la envolvente no se encuentran posibles patrones válidos.

El siguiente paso fue el análisis de parámetros que contienen información tanto del dominio del tiempo como del de la frecuencia, concretamente utilizando la WT. Sin embargo, el uso de esta técnica es algo muy complejo ya que conlleva la selección de múltiples parámetros, como el tipo de análisis a realizar, así como la Wavelet madre o el nivel de descomposición. Existen

trabajos previos que muestran la efectividad del uso de los coeficientes del MRA, tanto en el caso de rodamientos [57] como en el caso de ejes [24]. Sin embargo, el uso de la energía de la WPT mejora estos resultados, como se puede observar en [108] para el caso de los rodamientos. Además, el uso de la energía WPT ofrece ventajas: cada paquete generado se define a través de un único valor de energía. Cada paquete puede cubrir un ancho de banda muy diferente, que viene determinado por la frecuencia de muestreo y el nivel de descomposición. De esta manera, el ancho de banda deseado se puede analizar de forma sencilla. Esto ofrece una ventaja muy importante respecto al uso de los coeficientes WPT o a la PSD, y es que facilita la automatización de la selección de ciertos parámetros. Por lo tanto, teniendo en cuenta sus prometedores resultados, así como las ventajas que proporciona, se selecciona como posible patrón óptimo la energía WPT.

Sin embargo, como se explicó anteriormente, el uso de la WPT no es algo sencillo, ya que implica la selección de varios parámetros, que son:

- Wavelet madre
- Nivel de descomposición

En cuanto a la Wavelet madre, se realizó un estudio previo para este caso en particular, que se puede consultar en [109]. Aunque en la bibliografía no existe una metodología definida para seleccionar la Wavelet madre, en este caso se atendió principalmente a que la distribución de las medias de las energías de los paquetes de interés fuera normal, y a que la desviación estándar de dichas medias fuera lo más reducida posible. Atendiendo a estos criterios, la Wavelet madre seleccionada fue la ‘db6’, que además ha presentado buenos resultados en trabajos previos en defectología, como en [57, 108, 4].

La selección del nivel de descomposición está directamente relacionada con la selección de parámetros locales de la señal de la que se hablaba en el capítulo 3. En la figura 3.4 se mostraban las dos aproximaciones utilizadas en la presente Tesis Doctoral para la selección de parámetros locales: la primera de ellas está basada en los patrones que resultan del estudio bibliográfico y teórico, y la segunda en los resultados obtenidos del estudio global de las señales experimentales.

A continuación se detallan los estudios realizados mediante las dos aproximaciones para obtener los parámetros locales de las señales (y en este caso también el nivel de descomposición), así como los diseños de los sistemas de clasificación en cada caso y las curvas POD generadas. Finalmente, se realizará una comparación de los resultados obtenidos mediante los dos métodos, para la selección de la técnica de diagnóstico óptima.

7.1. Selección de parámetros locales según los resultados teóricos

Como se estudió en el capítulo 2, según la bibliografía, las frecuencias de fallo en ejes se corresponden con subarmónicos de la velocidad crítica, o armónicos de la velocidad de giro. Sin embargo, no hay un consenso sobre qué frecuencias son las que experimentan mayores cambios con la aparición de un defecto, y además siempre ha habido ciertos problemas para traducir estas frecuencias de fallo en resultados fiables de diagnosis experimentales, sobre todo a bajas velocidades. Debido a esta falta de consenso, se realiza un modelo de rotor Jeffcott incluyendo una función de respiro, que recree el comportamiento dinámico del eje estudiado en el presente trabajo, bajo las mismas condiciones de los ensayos experimentales. Con este modelo se pretenden buscar las frecuencias de fallo que, en teoría, son las más adecuadas para realizar una diagnosis en el caso de estudio.

Por ello en la presente sección se analizan, en primer lugar, las señales obtenidas del modelo teórico, comparando las de eje sano con las de eje defectuoso con el fin de observar los efectos que provoca una fisura. Para ello se realiza un estudio de las energías obtenidas mediante WPT.

Posteriormente, se intentarán localizar en las señales experimentales los fenómenos observados en los resultados teóricos cuando aparece un defecto. Los resultados obtenidos se utilizan para diseñar un sistema de clasificación.

7.1.1. Modelo de rotor Jeffcott con función de respiro

En los últimos años se han dedicado grandes esfuerzos a entender el comportamiento dinámico de maquinaria rotativa defectuosa. En este trabajo, se ha seleccionado el modelo más popular para el estudio, el modelo de rotor Jeffcott. Las ecuaciones aplicadas son las que se presentaron en la sección 2 en las expresiones 2.3 y 2.4, obtenidas a partir de la aplicación de la segunda ley de Newton al centro del disco. A estas ecuaciones, se les ha modificado el término relativo a las fuerzas elásticas, añadiéndose los efectos de los cambios de rigidez provocados por determinadas fisuras. Ya que el eje gira a bajas velocidades y bajo la carga de su propio peso, se asume que la grieta respira, según las condiciones dadas en [12]. Las ecuaciones del modelo, teniendo en cuenta una grieta con respiro, son las que se muestran en las expresiones 7.1 y 7.2.

$$M\ddot{x} + c\dot{x} + kx - \frac{1}{2}G(\phi)[(\Delta k1 + \Delta k2 \cos(2\phi))x + \Delta k2 \sin(2\phi)y] = M\rho\omega^2 \cos(\varphi_0 + \omega t) \quad (7.1)$$

$$M\ddot{y} + c\dot{y} + ky - \frac{1}{2}G(\phi)[\Delta k2 \sin(2\phi))x + (\Delta k1 - \Delta k2 \cos(2\phi))y] = Mg + M\rho\omega^2 \cos(\varphi_0 + \omega t) \quad (7.2)$$

Donde M es la masa de la barra, c el coeficiente de amortiguamiento, k la rigidez del sistema y ρ la distancia que el centro del disco está desplazado respecto a su eje. El valor g es el de la gravedad, y la función G representa la función de respiro, es decir, los momentos en que la fisura se encuentra abierta o cerrada. $\Delta k1$ representa el factor de variación de rigidez en la dirección de la fisura y $\Delta k2$ en la dirección perpendicular a la misma. La función de respiro utilizada en este trabajo es la de Mayes and Davies, que puede observarse en la figura 2.2, y cuya ecuación es la mostrada en 7.3.

$$G(\phi) = \frac{1 + \cos(\phi)}{2} \quad (7.3)$$

Para implementar las ecuaciones y obtener las aceleraciones en el centro del disco, se utiliza un modelo en variables de estado [110], del tipo que se muestra en las ecuaciones 7.4 y 7.5.

$$\dot{z} = Az + Bu \quad (7.4)$$

$$y = Cz + Du \quad (7.5)$$

Donde z es un vector columna que contiene todas las variables de estado en un instante determinado, \dot{z} contiene el valor de dichas variables en la iteración inmediatamente posterior, u es un vector que contiene las entradas o las variables controlables del modelo, e y representa la salida del sistema. A , B , C y D son matrices que representan las relaciones lineales existentes entre todas las variables.

Las salidas de este modelo son las señales de aceleración que aparecen en el eje durante su funcionamiento en la dirección vertical. Se realizarán ensayos a diferentes velocidades en estado estacionario con y sin fisuras, de forma análoga a las mediciones experimentales. En este caso, las entradas lógicas del sistema deberían ser los parámetros que definen el sistema: la posición angular del rotor, ϕ , su derivada la velocidad angular ω , y/o la aceleración angular $\dot{\omega}$. Sin embargo, utilizando estas variables como entradas (componentes del vector u), el sistema de ecuaciones obtenido no es lineal, como se esperaba a partir de las ecuaciones propuestas para su resolución, por lo que se hace necesario un cambio de variable. Para el sistema estudiado, el número de variables de estado será seis, que representan las posiciones, velocidades y aceleraciones que aparecen en el eje en las direcciones x e y , con lo cual, para cada instante, z será un vector columna con seis filas que se corresponden con:

$$z = [z_1, \dots, z_6]' \quad (7.6)$$

$$z_1 = x \quad (7.7)$$

$$z_2 = y \quad (7.8)$$

$$z_3 = \dot{x} \quad (7.9)$$

$$z_4 = \dot{y} \quad (7.10)$$

$$z_5 = \ddot{x} \quad (7.11)$$

$$z_6 = \ddot{y} \quad (7.12)$$

Al derivar el vector z , obtenemos \dot{z} :

$$\dot{z} = [\dot{z}_1, \dots, \dot{z}_6]' \quad (7.13)$$

$$\dot{z}_1 = z_3 \quad (7.14)$$

$$\dot{z}_2 = z_4 \quad (7.15)$$

$$\dot{z}_3 = z_5 \quad (7.16)$$

$$\dot{z}_4 = z_6 \quad (7.17)$$

$$\dot{z}_5 = u_1 \quad (7.18)$$

$$\dot{z}_6 = u_2 \quad (7.19)$$

Con esto, el sistema se linealiza y se puede resolver según las ecuaciones propuestas. Las entradas u_1 y u_2 representan las derivadas de la aceleración en los ejes x e y , que dependen de la posición, velocidad, y aceleración angular, y que se irán actualizando en cada iteración. De esta forma se tendría un sistema lineal y capaz de ser implementado. Las expresiones de u_1 y u_2 se obtienen de las ecuaciones 7.1 y 7.2, despejando \ddot{x} e \ddot{y} respectivamente, y derivando las expresiones obtenidas. Sustituyendo además las variables existentes en las ecuaciones por las del modelo en variables de estado se obtienen las expresiones buscadas de u_1 y u_2 .

La salida, o vector y del sistema, coincide con el vector de variables de estado x . Se extraerán por tanto todas las señales de posición, velocidad y aceleración en las dos direcciones, aunque la señal que se está buscando es la aceleración en el eje vertical, z_6 .

Así, conociendo estas ecuaciones, ya se podrían determinar las matrices A , B , C y D . El modelo, cuyo esquema puede observarse en la figura 7.1, se ha implementado mediante una *S-Function*, disponible en el entorno *Simulink*[®] de *Matlab*[®].

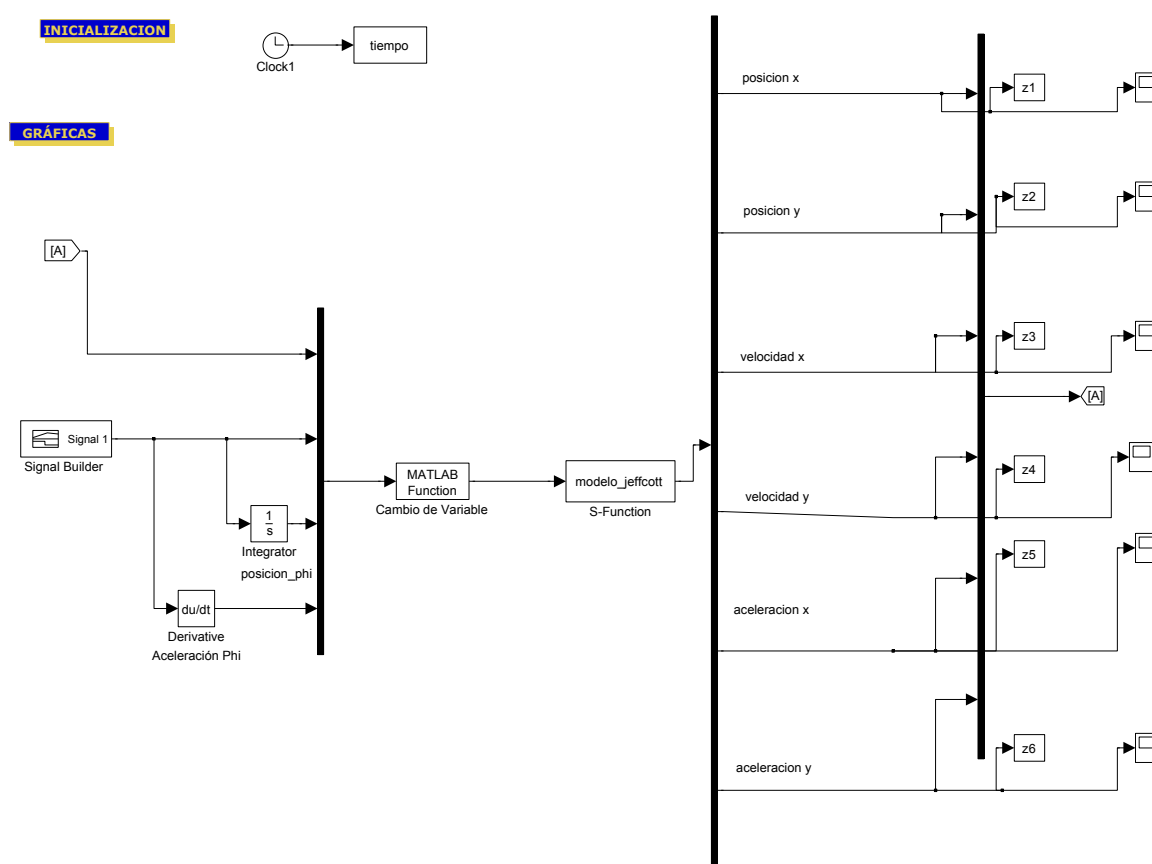


Figura 7.1: Modelo de rotor Jeffcott implementado en variables de estado

En él se pueden controlar tanto el tiempo total de la simulación, como el paso de integración para calcular el valor de las variables en la iteración posterior, que serán fijados de forma análoga a los parámetros de las señales experimentales (es decir, se fijará una frecuencia de muestreo de

6000Hz y un tiempo de simulación de 2,73s).

Las propiedades del sistema (constantes del modelo) se asignan mediante el botón ‘inicialización’. Desde el bloque *signal builder* se genera la función de velocidad deseada, que será la entrada del sistema. Esta función es integrada y derivada para conocer también la posición angular y la aceleración angular. Tanto esta información, como el valor de las variables la iteración anterior (almacenadas en el bloque *A*), son los parámetros de entrada de la función llamada ‘cambio de variable’. En esta función se realiza el cambio de variable de posición, velocidad y aceleración angular, que serían las entradas naturales del sistema, a $u1$ y $u2$, que son las entradas del modelo en variables de estado después de convertirlo en lineal.

Cabe destacar que, mientras que en el sistema experimental las señales se obtienen desde un apoyo (concretamente desde el alojamiento del rodamiento) en el modelo teórico de rotor Jeffcott la salida se corresponde con la señal de aceleración en el centro del eje. Debido a esto, las señales temporales no se pueden comparar en ningún caso en términos de amplitud. Los resultados del modelo teórico sirven simplemente para examinar a nivel cualitativo qué ocurre cuando aparece un defecto.

En el caso del modelo teórico, se simulan 4 tipos de fallo con el fin de comprobar cuáles son las principales consecuencias al introducir un defecto y su evolución. Los niveles estudiados, y sus factores de variación en la rigidez son:

- Eje sano, utilizando $\Delta k1 = 0$
- Eje fisurado con una profundidad del 12,5 % respecto de su diámetro, o un porcentaje afectado de sección del 10,95 %, utilizando $\Delta k1 = 0,05$.
- Eje fisurado con una profundidad del 25 % respecto de su diámetro, o un porcentaje afectado de sección del 29,20 %, utilizando $\Delta k1 = 0,12$.
- Eje fisurado con una profundidad del 50 % respecto de su diámetro, o un porcentaje afectado de sección del 50 %, utilizando $\Delta k1 = 0,206$.

Para todos los casos, $\Delta k2$ (factor de variación de la rigidez en la dirección perpendicular a la fisura) es la cuarta parte de $\Delta k1$.

Para cada caso de defecto y de velocidad se generará únicamente una señal ya que, en el modelo teórico, no existe ruido ni elementos que puedan perturbar la señal y siempre se obtendrían los mismos resultados.

En la figura 7.2 se pueden observar ejemplos de las señales temporales obtenidas a la velocidad de 20Hz, para las cuatro condiciones de defecto. La amplitud de las señales parece aumentar progresivamente con el tamaño de defecto desde $3 \cdot 10^{-3}$ cuando el eje está sano hasta $3,5 \cdot 10^{-3}$ para el caso de defecto del 50 %.




Figura 7.2: Señales temporales obtenidas del modelo teórico a 20Hz (a) Eje sano (b) Eje con defecto del 12,5 % del diámetro (c) Eje con defecto del 25 % del diámetro (d) Eje con defecto del 50 % del diámetro

En la figura 7.3 se pueden ver las transformadas de Fourier, de las señales de la figura 7.2 para el caso de 20Hz. En dichas señales se ha hecho un aumento para que se puedan apreciar de forma nítida los efectos de una fisura y su progresión. Se puede concluir que, cuando el eje está sano, la única frecuencia significativa en la señal es la de la velocidad de giro, es decir, la 1x, que en el caso de la figura se corresponde con 20Hz. Cuando aparece un defecto, la amplitud de esta frecuencia aumenta, y además se hacen significativos los armónicos de la velocidad de giro 2x (40Hz) y 3x (60Hz). El aumento de estas frecuencias adquiere mayor importancia cuanto mayor es el tamaño del defecto. Este fenómeno se observa también en el resto de velocidades analizadas.

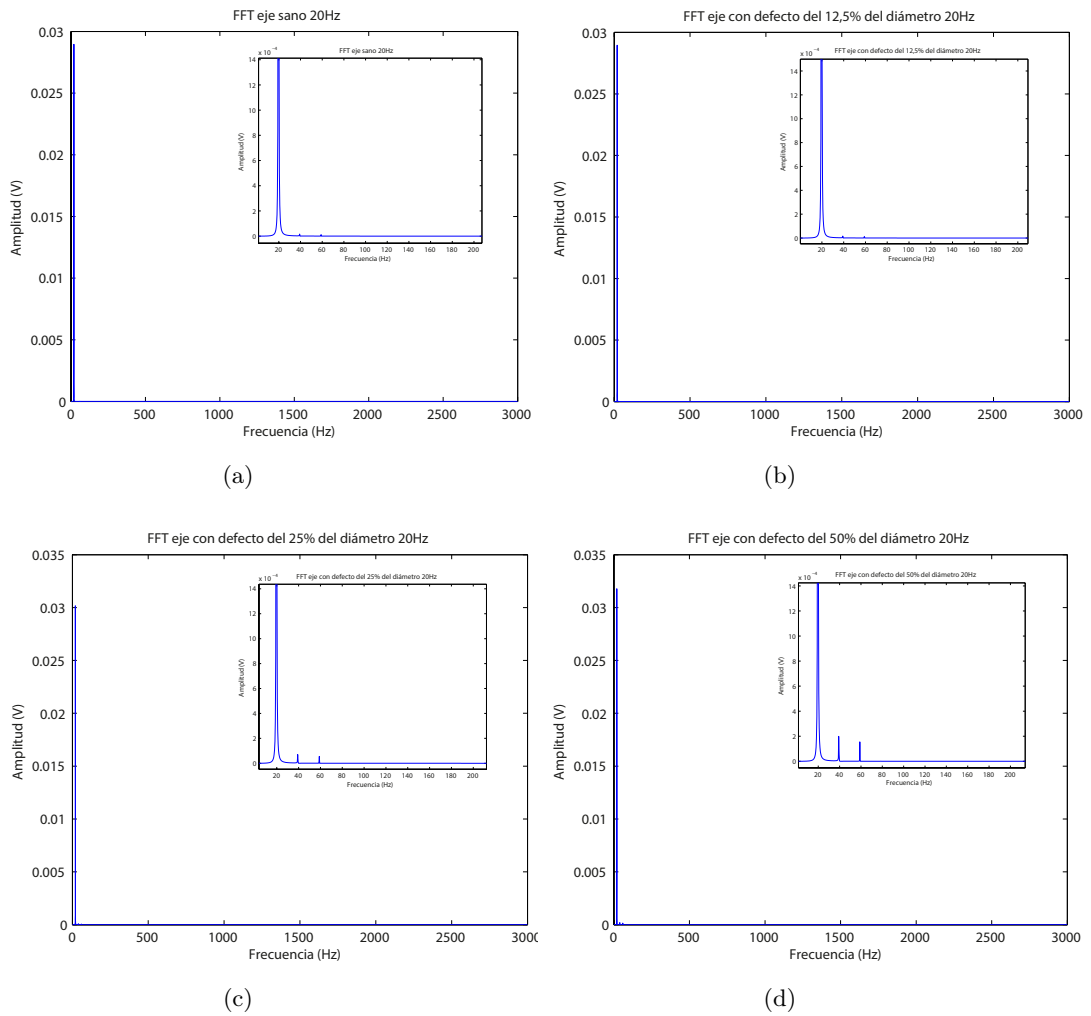


Figura 7.3: Transformada de Fourier de las señales obtenidas del modelo teórico a 20Hz (a) FFT eje sano (b) FFT eje con defecto del 12,5 % del diámetro (c) FFT eje con defecto del 25 % del diámetro (d) FFT eje con defecto del 50 % del diámetro

Estos resultados confirman que la energía de ciertos armónicos de la velocidad de giro aumentan con la presencia de un defecto. Por otro lado, en los resultados obtenidos del modelo teórico para el caso particular del eje de estudio, el armónico 3x de la velocidad de giro adquiere una especial relevancia que, según la bibliografía, tienen principalmente el 1x y el 2x [10].

A continuación se detallará el estudio de las energías WPT tanto para las señales obtenidas

del modelo teórico como para las señales experimentales.


7.1.2. Análisis de las energías obtenidas mediante WPT de las señales obtenidas mediante el modelo teórico

A la vista de los resultados obtenidos mediante el análisis de la FFT, a continuación se estudiarán los aumentos de energía de la señal cuando aparece un defecto mediante la energía WPT.

Para aplicar la transformada en paquetes Wavelet (WPT), en primer lugar se selecciona el nivel de descomposición. Este valor determina el ancho de banda de cada paquete f_r , de acuerdo a la ecuación 4.25 de la sección 4.3. El ancho de banda de cada paquete debe ser lo suficientemente amplio para cubrir la frecuencia buscada teniendo en cuenta posibles errores. Sin embargo, cuanto mayor sea este valor, existe mayor riesgo de que se tomen en consideración fenómenos ajenos a la frecuencia de interés. También se debe tener en cuenta que, al aumentar el número de paquetes generado (o el nivel de descomposición) y, por tanto, reducir el valor f_r , se estará aumentando el coste computacional requerido para las transformaciones.

Para este método se considera adecuado, a la vista de los resultados del modelo teórico y después de análisis previos, el estudio de la señal en bandas de frecuencia o paquetes con un valor f_r de aproximadamente 6Hz. Como la señal es muestreada a 6.000Hz, y por tanto solo puede ser reconstruida hasta los 3.000Hz, el nivel de descomposición seleccionado será el 9.

Una vez seleccionado el nivel de descomposición se llevan a cabo las transformaciones pertinentes de las señales para calcular la energía utilizando la transformada WPT sin normalizaciones, con la Wavelet madre ‘Daubechies 6’ (db6) y nivel de descomposición 9. Así, para cada señal transformada, resulta una distribución de 512 (2^9) paquetes de energía, como la que se muestra de ejemplo en la figura 7.4.



de 20Hz. En la figura se ha realizado un aumento sobre los paquetes que tienen niveles de energía relevantes, ya que en su mayoría éstas valen cero. Cada paquete se corresponde con una banda de frecuencia de aproximadamente 6Hz, y el orden de frecuencias es el resultante de la WPT en *Matlab*[®], que no se corresponde con el orden de frecuencias natural.

En los datos del modelo teórico se observa que, en ciertas bandas de frecuencia, se producen incrementos de energía cuando aparece un defecto. Para obtener más información sobre estos aumentos se han calculado, para cada caso de velocidad, las diferencias entre las energías de cada nivel de defecto respecto a las energías obtenidas para el caso de eje sano, según se observa en la figura 7.5.

Del cálculo de estas diferencias, se obtienen finalmente tres distribuciones de 512 valores que contienen los aumentos de energía respecto al eje sano (una para cada caso de defecto, 12,5 %, 25 % y 50 %). Analizando estas distribuciones se encuentra que existen seis paquetes coincidentes para los que estos aumentos de energía adquieren un valor significativo, y además dichos paquetes tienen el mismo orden de relevancia para todos los casos de defecto. Además se observa que, las diferencias son mayores cuanto mayor es el nivel de defecto. Esto ocurre para todos los casos de velocidad.

En la tabla 7.1 se muestran los seis paquetes que presentan un aumento de la energía con la presencia de un defecto, para cada caso de velocidad. Dichos paquetes han sido ordenados de mayor a menor según la relevancia del aumento de energía experimentado. Para cada paquete se muestra la banda de frecuencia a la que hace referencia, así como su relación, si existe, con la velocidad de giro (1x, 2x o 3x).

Velocidad de giro (Hz)	Orden según relevancia	Banda de frecuencia (Hz)
20	1	17,6-23,4 (1x)
	2	23,4-29,3 (vecino 1x)
	3	35,2-41 (2x)
	4	52,7-58,6 (vecino 3x)
	5	58,6-64,5 (3x)
	6	41-46,9 (vecino 2x)
40	1	35,2-41 (1x)
	2	29,3-35,2 (vecino 1x)
	3	41-46,9 (vecino 1x)
	4	76,2-82 (2x)
	5	111,3-117,2 (vecino 3x)
	6	117,2-123 (3x)
60	1	58,6-64,5 (1x)
	2	52,7-58,6 (vecino 1x)
	3	64,5-70,3 (vecino 1x)
	4	117,2-123 (2x)
	5	175,8-181,6 (3x)
	6	181,6-187,5 (vecino 3x)

Tabla 7.1: Bandas de frecuencia significativas ordenadas según mayores incrementos absolutos de energía respecto al eje sano para las señales obtenidas del modelo teórico

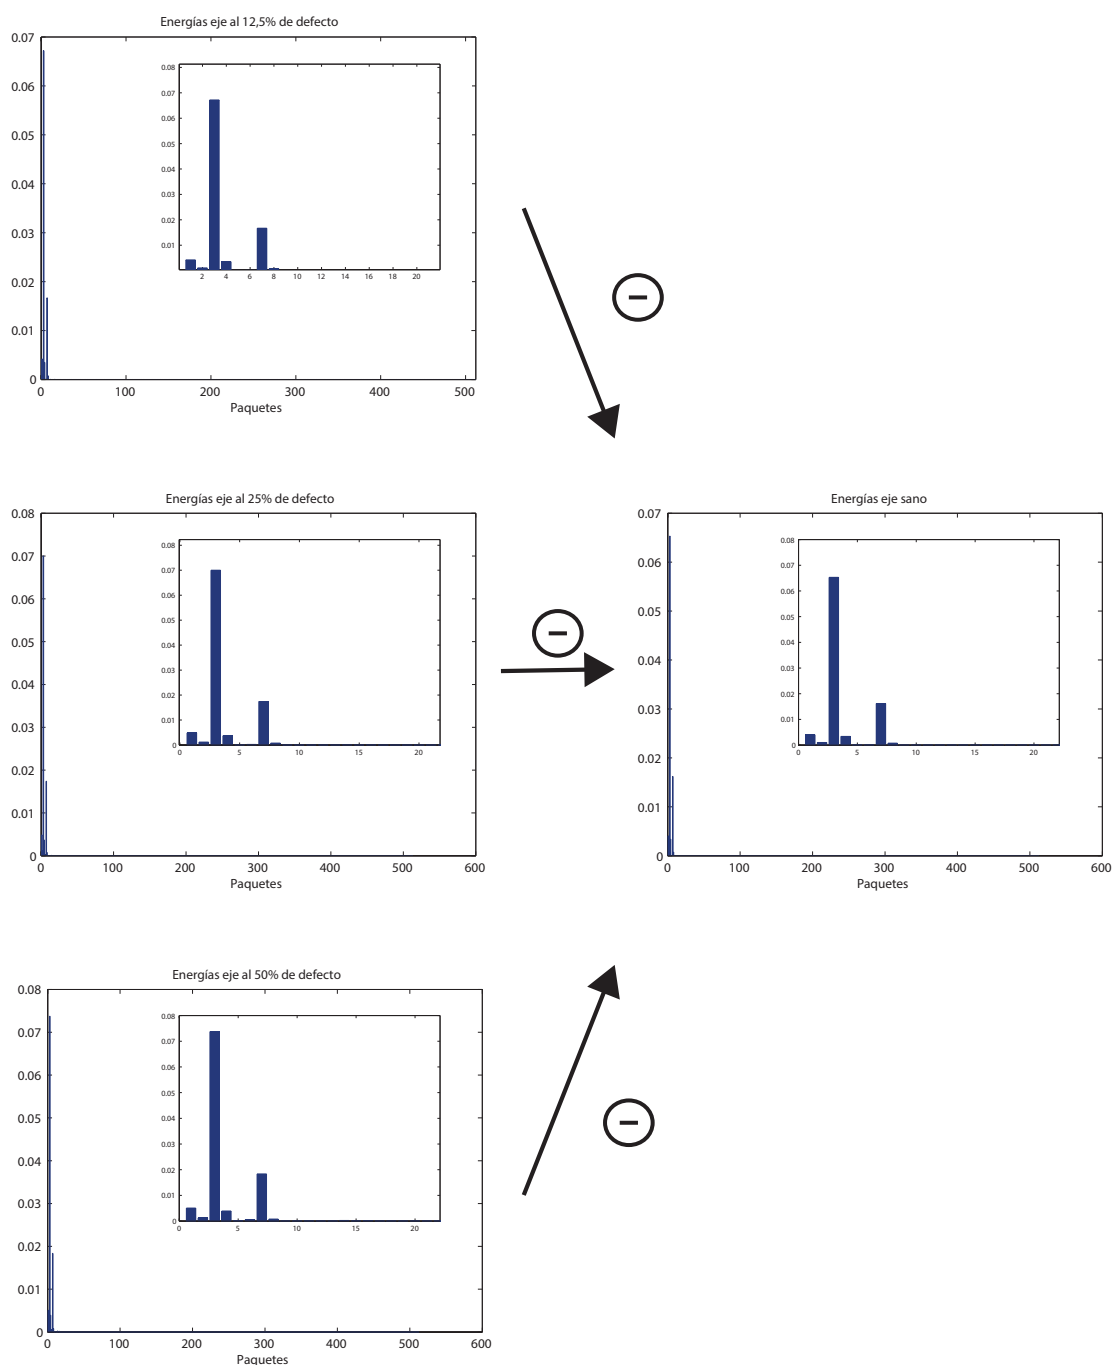


Figura 7.5: Cálculo de las diferencias de energías entre eje sano y eje con defecto para cada caso de velocidad

De la tabla 7.1 se puede concluir que, analizando las energías obtenidas mediante WPT, las diferencias absolutas más significativas están siempre relacionadas con los armónicos de la velocidad de giro y se obtienen en las componentes 1x, 2x y 3x de la misma, y además en este orden. Sin embargo, en este caso también se puede observar un nuevo fenómeno debido al uso de la WPT: los vecinos más cercanos a estas componentes también se ven afectados por estos cambios de energía de forma significativa. Este hecho se ha observado también tratando con señales senoidales puras, en las que las bandas de frecuencia cubrían perfectamente las frecuencias buscadas. Este fenómeno se puede achacar a la no inmediatez de los filtros aplicados por la WPT, que causan una duplicación de algunas frecuencias en paquetes vecinos.

En las figuras 7.6, 7.7, y 7.8 se muestran los resultados del cálculo de los incrementos de energía en términos relativos respecto a los valores de eje sano. En dichas figuras los incrementos se muestran como función de los paquetes (ordenados por relevancia según los incrementos absolutos, de acuerdo a la tabla 7.1) para todos los casos de velocidad.




Figura 7.6: Incrementos relativos de energía (%) en función de los paquetes significativos ordenados por relevancia, para el caso de velocidad de 20Hz

Como se muestra en las figuras, los incrementos relativos respecto a los valores de eje sano no tienen el mismo orden de relevancia que se obtenía para el caso de incrementos absolutos, que se mostraba en la tabla 7.1. Es decir, si se ordenaran por relevancia los paquetes según sus incrementos relativos, se obtendría otro orden diferente. En el caso de la velocidad de rotación de 20Hz, el paquete que sufre los mayores incrementos relativos es el paquete que tenía la posición de relevancia número 4 en términos absolutos, y para las velocidades de 40Hz y 60Hz, el paquete más significativo es, en ambos casos, el que tenía la posición 5. Para todos los casos de velocidad, se puede comprobar en la tabla 7.1 que estos paquetes que presentan los incrementos relativos máximos están relacionados con el armónico 3x (valores del propio paquete que contiene esta frecuencia o su vecino). Sin embargo, en términos absolutos, los paquetes más significativos estaban relacionados con las frecuencias 1x y 2x.

Para el caso de las energías relativas a la velocidad de 20Hz, se observan valores muy elevados, sobre todo para los paquetes 3, 4, y 5. Esto ocurre porque los valores de esos paquetes para eje sano eran muy próximos a cero, por lo que al ser utilizados como cociente en un denominador,




Figura 7.7: Incrementos relativos de energía (%) en función de los paquetes significativos ordenados por relevancia, para el caso de velocidad de 40Hz




Figura 7.8: Incrementos relativos de energía (%) en función de los paquetes significativos ordenados por relevancia, para el caso de velocidad de 60Hz

generan valores muy altos.

Además, es fácilmente deducible que, si aumenta la energía de ciertos paquetes de la señal, la energía total de la misma también experimentará un aumento. Por esto, en la figura 7.9 se pueden observar también los valores de aumento de energía relativos de la señal respecto al valor de energía en el eje sano, según la velocidad. Los aumentos relativos en la energía total parecen mucho menores que los aumentos relativos de energía en los paquetes más significativos, aunque también están presentes.




Figura 7.9: Incrementos relativos de energía total de la señal respecto a eje sano para las señales obtenidas del modelo teórico

7.1.3. Análisis de energías de las señales experimentales en las frecuencias teóricas de fallo

Según se ha concluido a partir del estudio de las señales obtenidas del modelo teórico, cuando aparece un defecto, se producen aumentos muy significativos de la energía, principalmente en componentes relacionadas con las frecuencias $1x$, $2x$, y $3x$ en términos absolutos, aunque los mayores aumentos relativos aparecen en $3x$. A continuación, se tratará de determinar si los aumentos de energía en estas componentes también están presentes en las señales experimentales (si los valores de energía de estos paquetes se pueden considerar posibles patrones óptimos). En el caso de que sea así, se tratará de diseñar un sistema de clasificación que cuantifique los resultados de fiabilidad de forma exhaustiva.

Para buscar posibles aumentos de energía en las frecuencias teóricas de fallo sobre las señales experimentales, solamente se va a tener en cuenta el rango de frecuencias $[0,5x]$ para cada caso de velocidad, para cubrir las frecuencias de interés. Para ello, en primer lugar, se realizan las transformaciones para obtener las energías WPT de las señales experimentales, utilizando como Wavelet madre la 'db6' y como nivel de descomposición el 9. En la figura 7.10 se muestra un ejemplo del resultado obtenido de la transformación, para una señal tomada a 20Hz para el caso de eje sano.

De estos 512 valores de energía obtenidos, se seleccionan únicamente los relativos a la banda de frecuencias $[0,5x]$ para cada caso de velocidad. A diferencia de los datos obtenidos mediante el modelo teórico, el número de señales experimentales adquiridas es muy elevado. Como se explicó en la sección 6.2.5, tomar un valor promedio de poblaciones tan elevadas, implicaría un error de aproximadamente el 3,5 % respecto al promedio real en el peor de los casos. Por ello, por simplificar los resultados, para la selección de posibles patrones óptimos se trabajará con los promedios de cada condición del eje analizada. Para cada patrón seleccionado, se realizarán cálculos estadísticos más exhaustivos para calcular las curvas POD.

Una vez extraídos los promedios de energía de cada condición de defecto para los paquetes




Figura 7.10: Energías obtenidas mediante WPT para una señal experimental a nivel de descomposición 9 para eje sano a 20Hz

relativos a las bandas $[0,5x]$, se procede de forma análoga que para el caso teórico: se analizan los aumentos o diferencias de energías entre los distintos niveles de defecto y el eje sano. Para seleccionar los posibles patrones óptimos, se buscan los paquetes que experimenten mayores aumentos de energía en términos absolutos cuando aparezca un defecto. No se analizan aumentos relativos ya que se podría cometer el error de considerar muy significativo un aumento de energía prácticamente inapreciable, sólo por el hecho de que el valor de eje sano fuera insignificante. Una vez seleccionados los paquetes, sí que se realizarán estudios sobre los aumentos relativos.

Al realizar un estudio sobre los aumentos de energía en este caso existen dos paquetes que, para todos los casos analizados, aparecen como buenos indicadores de defecto: el que contiene la frecuencia $3x$ y su vecino más cercano. Por otra parte, los paquetes que contienen las frecuencias $1x$ y $2x$, así como otros analizados, no aparecen como significativos con repetibilidad. Por ello se decidió realizar un análisis utilizando promedios de los grupos de 100 señales tomadas consecutivamente, para tener más datos. De estos dos análisis se concluyó que, los únicos aumentos de energía significativos, y que además se dan con una alta repetibilidad en las señales obtenidas, se dan en los paquetes relativos a la frecuencia $3x$ que se muestran en la tabla 7.2.

Después de realizar un estudio sobre la evolución de la energía total de la señal (utilizando los valores promedio), se ha observado que también para las señales experimentales su valor aumenta con la presencia de un defecto.

Por tanto, a partir del estudio de los resultados teóricos, se seleccionan como posibles patrones óptimos la energía WPT de los paquetes que contienen la frecuencia $3x$, su vecino más cercano, y la energía total de la señal. Una vez seleccionados estos patrones, se diseña un sistema de clasificación para cada uno de ellos, cuyos resultados se muestran en la siguiente sección.

7.1.4. Diseño del sistema de clasificación: método de señal de respuesta

En esta sección se muestra la clasificación realizada para cada uno de los posibles patrones óptimos seleccionados a partir del estudio teórico. La finalidad es calcular las curvas POD que

Velocidad de giro (Hz)	Bandas de frecuencias significativas por orden (Hz)
20	52,7-58,6 (vecino 3x)
	58,6-64,5 (3x)
40	117,2-123 (3x)
	111,3-117,2 (vecino 3x)
60	181,6-187,5 (vecino 3x)
	175,8-181,6 (3x)

Tabla 7.2: Bandas de frecuencia más representativas de defecto, según los cambios en energía respecto al eje sano, para las señales experimentales

servirán de indicador de la fiabilidad de los métodos propuestos.

Del estudio previo de energía WPT en las señales experimentales, se ha concluido que los paquetes que experimentan un mayor aumento de energía cuando aparece un defecto son los relativos a la frecuencia 3x, y que la energía total de la señal también experimenta aumentos significativos. Estos patrones seleccionados como candidatos a óptimos tienen una estructura simple: consisten cada uno de ellos en un valor de energía. A partir de este conocimiento sería factible el diseño de un sistema de clasificación mediante el método \hat{a} vs. a o de señal de respuesta, explicado en la sección 5.1, que se basa en el establecimiento de un valor umbral \hat{a}_u para el parámetro escogido. Cuando este valor se sobrepasa, se dice que el elemento tiene un defecto. Cuando el valor es menor al valor umbral, el resultado de la diagnosis es que el elemento está sano. Las curvas POD se generan mediante el cálculo de probabilidades de que el parámetro supere o no el valor umbral.

Se diseñará un sistema de clasificación para cada uno de los tres posibles patrones óptimos: la energía del paquete que contiene a 3x, la energía del paquete vecino más cercano al que contiene a 3x, y la energía total de la señal. De esta manera, posteriormente se podrá discernir cuál de ellos es el que arroja los resultados de diagnosis más fiables.

La selección del valor umbral para el método de señal de respuesta se realiza fundamentalmente mediante prueba-error. Este valor se va ajustando con el fin de encontrar el valor que optimiza los valores de probabilidad de detección, es decir, el que mejor separa los datos de eje sano y eje defectuoso. El criterio utilizado para ir ajustando el valor umbral será, principalmente, el que pueda diagnosticar de forma fiable los casos en que el eje está sano, en los que tiene un defecto grande. Una vez consideradas las tasas de acierto, se determinará si el método es fiable o no.

Con el fin de obtener resultados más fiables, se pretende realizar la diagnosis utilizando como posible patrón óptimo la/s energía/s seleccionada/s en su valor promedio por grupos de 100 de cada condición ya que, tal y como se explicó en la sección 6.2.5, esto reduce efectos indeseables en la señal.

Para este trabajo, se toma como hipótesis inicial que la distribución de energías de los paquetes seleccionados como posibles patrones óptimos es log-normal, es decir, crece exponencialmente con el tamaño de defecto. Según esto, para cada condición medida, la distribución de logaritmos de las energías es una normal según la media de los logaritmos y la desviación estándar de todos ellos. Sin embargo, el teorema central del límite [104] afirma que, si se toman n grupos de muestras para cada condición, la distribución de medias muestrales de estas variables independientes tiende hacia una distribución normal, aunque las muestras procedan de una distribución

no normal. Esto quiere decir que, para una misma condición de velocidad y de defecto del eje, si se toman n grupos de 100 medidas y se obtienen los n promedios de energías, dichos promedios tenderán hacia una distribución normal.

En la presente Tesis Doctoral se toman un mínimo de $N = 1.600$ medidas para cada condición de defecto y velocidad del eje, tomadas por grupos de 100 medidas consecutivas. Suponiendo que, según la hipótesis inicial, los logaritmos de todas las energías siguen una distribución normal (con media igual a la media de los logaritmos y la desviación estándar de los mismos), se podría calcular mediante la función de distribución acumulativa de la normal la probabilidad de que cada uno de estos grupos de datos tome un valor mayor o menor al logaritmo del valor umbral. En la figura 7.11 se pueden observar las distribuciones de los logaritmos de energías del paquete vecino a 3x a 20Hz para cada condición de defecto, que se aproximarían a una normal. Esto representaría el logaritmo del valor de la respuesta $\ln(\hat{a})$, (en este caso el logaritmo de la energía $\ln(E)$). También se muestra el logaritmo del valor umbral, $\ln(\hat{a}_u)$ establecido para este caso.




Figura 7.11: Distribución de los logaritmos de los datos de energía (V^2) del paquete vecino a 3x (media y desviación estándar global) a 20Hz

Por tanto, en este caso, se dispone de n medias muestrales, $\mu_1(a), \mu_2(a) \dots \mu_n(a)$, cada una de ellas calculada por grupos de 100 valores de energía para un nivel de defecto a y para una condición de velocidad. Según el teorema central del límite, las n medias muestrales de energía seguirían una distribución normal cuya media se calcularía como la media de las medias $\bar{\mu}_n(a)$, y cuya desviación estándar sería la desviación estándar de las medias $\sigma_{\bar{\mu}_n(a)}$. Recurriendo a la función de distribución acumulativa F de esta población normal, por tanto, sería posible calcular la probabilidad de que el valor de una media muestral $\mu_i(a)$ sea mayor al valor umbral establecido \hat{a}_u (es decir, la probabilidad de detectar un defecto de tamaño a) según la ecuación 7.20.

$$POD(a) = 1 - F\{z\} = 1 - F\left\{\frac{\hat{a}_u - \bar{\mu}_n(a)}{\sigma_{\bar{\mu}_n(a)}}\right\} \quad (7.20)$$

En este trabajo se recurrirá a la distribución de medias muestrales para calcular las probabilidades, (ecuación 7.20), donde $\bar{\mu}_n(a)$ será el valor promedio global de los promedios de la

energía calculados por grupos de 100, y $\sigma_{\bar{\mu}_n(a)}$ será la desviación estándar de estos promedios. Estos valores se calcularán independientemente para cada una de las tres distribuciones de energía seleccionadas como posible patrón óptimo. Se recurre a estas distribuciones para el cálculo de probabilidades ya que los valores obtenidos serán independientes de que se cumpla o no la hipótesis inicial sobre la distribución log-normal de datos. Además, el objetivo es realizar la diagnosis mediante estos valores promedio, ya que se obtendrán resultados más precisos por eliminar efectos indeseados. Si se cumple la hipótesis inicial, calcular las probabilidades utilizando esta distribución sería equivalente a calcularlas mediante la ecuación 5.4, en la que se utiliza la distribución de logaritmos.

En la figura 7.12, se muestra la energía del paquete vecino al que contiene a 3x para el caso de 20Hz, para cada nivel de defecto. Estas energías vienen representadas por la media y la desviación estándar de los promedios por grupos de 100 para cada nivel de defecto, ya que se considera que siguen una distribución normal. Además, se muestra el valor umbral seleccionado para este caso por ser el que mejor separa los datos, aunque no se puede establecer una buena diferenciación entre unas distribuciones y otras.




Figura 7.12: Distribución de las medias muestrales de los datos de energía (V^2) del paquete vecino a 3x (media y desviación estándar de las medias) a 20Hz

En las figuras 7.13 y 7.14 se observan también las distribuciones de las medias a 20Hz para el caso de las energías del paquete que contiene a la frecuencia 3x y para la energía total, con los valores umbrales seleccionados en cada caso. Como se puede observar, en ninguno de estos casos es posible identificar una separación de los datos de eje sano y de eje con defecto, debido a la elevada desviación estándar que tienen los datos de eje sano.

Las distribuciones de las medias de las energías relativas a los paquetes 3x a la velocidad de 40Hz, se pueden consultar en las figuras 7.15 y 7.16. La relativa a la energía total a 40Hz se muestra en la figura 7.17. En todos los casos se puede observar que es posible establecer una separación de los datos de eje sano y eje con defecto, ya que se distribuyen con ciertas diferencias que se hacen mayores cuando la severidad del defecto crece, sobre todo a partir del nivel de defecto 3.




Figura 7.13: Distribución de las medias de los datos de energía (V^2) del paquete 3x (media y desviación estándar de las medias) a 20Hz




Figura 7.14: Distribución de las medias de los datos de energía total (V^2) (media y desviación estándar de las medias) a 20Hz




Figura 7.15: Distribución de las medias de los datos de energía (V^2) del paquete vecino a 3x (media y desviación estándar de las medias) a 40Hz




Figura 7.16: Distribución de las medias de los datos de energía (V^2) del paquete 3x (media y desviación estándar de las medias) a 40Hz




Figura 7.17: Distribución de las medias de los datos de energía total (V^2) (media y desviación estándar de las medias) a 40Hz

En el caso de la velocidad de 60Hz, los resultados tienen una tendencia parecida a los obtenidos a 40Hz. En las figuras 7.18, 7.19 y 7.20 se muestran de nuevo las distribuciones de las medias relativas a 3x, las de la energía total y el valor umbral establecido para cada caso, a 60Hz. De nuevo parece que las distribuciones de eje sano y eje defectuoso se diferencian claramente, sobre todo a partir del defecto 3 para las energías relativas a 3x, y a partir del 4 para las energías totales.




Figura 7.18: Distribución de las medias de los datos de energía (V^2) del paquete vecino a 3x (media y desviación estándar de las medias) a 60Hz




Figura 7.19: Distribución de las medias de los datos de energía (V^2) del paquete 3x (media y desviación estándar de las medias) a 60Hz




Figura 7.20: Distribución de las medias de los datos de energía total (V^2) (media y desviación estándar de las medias) a 60Hz

Los resultados de clasificación obtenidos mediante el este sistema se exponen en la siguiente sección mediante las curvas POD en cada caso. Al final se presenta la validación de la hipótesis inicial.

7.1.5. Resultados de la metodología de selección de parámetros locales según los datos teóricos

En esta sección se muestran las curvas POD obtenidas para las distribuciones y valores umbrales establecidos para cada caso en la sección anterior.

En las figuras 7.21, 7.22 y 7.23 se exponen las curvas POD generadas a 20Hz para las energías del paquete vecino al que contiene a 3x, para las del paquete que contiene a 3x y para la energía total de las señales. De estas gráficas se puede concluir que, a la velocidad de 20Hz, los resultados no ofrecen en ningún caso suficiente fiabilidad.




Figura 7.21: POD obtenida a partir de la información del paquete vecino del que contiene la frecuencia 3x para el caso de velocidad de 20Hz




Figura 7.22: POD obtenida a partir de la información del paquete 3x para el caso de velocidad de 20Hz




Figura 7.23: POD obtenida a partir de la información de las energías totales de las señales para el caso de velocidad de 20Hz

En las figuras 7.24, 7.25 y 7.26 se muestran las curvas POD para la velocidad de 40Hz. Ambas curvas POD obtenidas para las energías relativas a 3x muestran resultados muy similares: un número reducido de falsas alarmas, tasas de acierto muy buenas para defectos a partir del nivel D3 (aproximadamente el 7,31 % de sección afectada), y un ligero decaimiento de la tasa de acierto para los niveles de defecto más críticos (D8 y D9), aunque sus tasas de acierto siguen siendo altas, ya que son próximas al 87 %. Para el caso de la energía total, el comportamiento de la curva POD obtenida es diferente: el número de falsas alarmas es más elevado ya que adquiere un valor de casi el 14 %, y no se obtiene fiabilidad al detectar defectos hasta que no adquieren un tamaño de al menos el nivel D5 (17,09 %), sin embargo, a partir de este nivel de defecto, todos se detectan con una fiabilidad de prácticamente el 100 %. Para el caso de la velocidad de 40 %, se considera más adecuado trabajar con los datos de energía de los paquetes relativos a 40Hz por su reducido número de falsas alarmas. Además, se considera que antes de llegar a un defecto de nivel D9 (50 % de la sección afectada), se pasa por otros que se detectan con mucha fiabilidad.




Figura 7.24: POD obtenida a partir de la información del paquete vecino a 3x para el caso de velocidad de 40Hz




Figura 7.25: POD obtenida a partir de la información del paquete que contiene la frecuencia 3x para el caso de velocidad de 40Hz




Figura 7.26: POD obtenida a partir de la información de las energías totales de las señales para el caso de velocidad de 40Hz

En las figuras 7.27, 7.28 y 7.29 se muestran las curvas POD calculadas para cada uno de los posibles patrones óptimos a la velocidad de 60Hz. Como se puede observar, utilizando los tres patrones se obtienen resultados de diagnosis fiables a partir de defectos de nivel D3, sobre todo para el caso de la energía del paquete vecino al que contiene a 3x. Además, para este caso se obtiene el menor número de falsas alarmas que está en torno al 5 %. La POD obtenida en este caso arroja los mejores resultados de clasificación obtenidos hasta este punto por ser la que más se asemeja a la POD ideal.




Figura 7.27: POD obtenida a partir de la información del paquete vecino del que contiene la frecuencia 3x para el caso de velocidad de 60Hz




Figura 7.28: POD obtenida a partir de la información del paquete 3x para el caso de velocidad de 60Hz




Figura 7.29: POD obtenida a partir de la información de las energías totales de las señales para el caso de velocidad de 60Hz

Como se puede observar, los resultados obtenidos mejoran a medida que aumenta la velocidad de rotación. Se puede concluir por tanto que, mediante esta aproximación, el patrón seleccionado como posible patrón óptimo es la energía del paquete vecino al que contiene a la frecuencia 3x, que experimenta aumentos significativos con la severidad de un defecto en el eje.

A continuación se pasará a comprobar si, tal y como se supuso inicialmente, la distribución de estas energías es log-normal.

7.1.5.1. Validación de la hipótesis inicial

Aunque esto no afectaba a los cálculos de probabilidad, se partió de la hipótesis inicial de que los datos obtenidos de las energías estudiadas siguen una distribución log-normal, es decir, que su logaritmo sigue una distribución normal respecto al logaritmo del tamaño de los defectos. En este apartado se procede a comprobar la hipótesis inicial sobre los datos que han generado mejores resultados de diagnóstico: la energía del paquete vecino al que contiene a la frecuencia $3x$ a la velocidad de 60Hz.

En la figura 7.30 se puede observar la representación de los logaritmos de las respuestas obtenidas frente a los logaritmos de los valores de los defectos, para el caso de la energía del paquete vecino al que contiene a $3x$. Estos valores muestran una fuerte correlación, ajustándose a una recta como la que se muestra en la ecuación 7.21:

$$y = 0,2655x + 0,0739 \quad (7.21)$$

El coeficiente de correlación obtenido para este ajuste es de 0,8 (siendo el valor de 1 el indicativo de una correlación de pendiente positiva perfecta y 0 el valor obtenido para una correlación nula). Con estos datos se puede dar por válida la hipótesis inicial.




Figura 7.30: Regresión de los datos del logaritmo de la energía (V^2) del paquete vecino a $3x$ frente al logaritmo del tamaño del defecto a 60Hz

7.1.6. Resumen de la metodología de selección de parámetros locales según los resultados teóricos

A partir del modelo teórico se han observado varios efectos que se producen en las energías obtenidas mediante WPT cuando aparece un defecto. Principalmente se observan aumentos en las energías en las frecuencias $1x$, $2x$ y $3x$, y también en la energía total de la señal. Analizando, para cada velocidad, los valores medios de la energía de los paquetes seleccionados para cada condición de defecto de cada una de estas energías seleccionadas como posibles patrones óptimos, se observa que los efectos que aparecen en el modelo teórico en las componentes $1x$ y $2x$, son

enmascarados en las señales experimentales. Por el contrario, analizando las energías en las bandas de frecuencia o paquetes que contienen la componente $3x$ de las señales y sus vecinos más cercanos, se observan aumentos significativos cuando aumenta la severidad del defecto. También se producen incrementos importantes en la energía total de las señales, de acuerdo con el caso teórico.

A la vista de estos fenómenos, se han propuesto como posibles patrones óptimos precisamente las energías del paquete que contiene la frecuencia $3x$ y su vecino más cercano, así como la energía total de la señal. Para cuantificar resultados de diagnóstico en cada caso generando las curvas POD, se ha recurrido al sistema de clasificación de señal de respuesta (importado de las técnicas de inspección no destructiva) debido a la sencillez de los patrones estudiados.

Este método se basa en el establecimiento de un valor umbral. Para cada condición del eje se calculan las probabilidades de que los datos medidos para dicha condición superen el valor umbral establecido. Una vez calculadas las curvas POD, se observa que los resultados de clasificación mejoran con la velocidad de giro, con lo que se puede concluir que a mayor velocidad de giro, los efectos de un defecto se hacen más visibles. Es posible achacar este hecho a que la relación señal-ruido es mayor cuanto mayor es la velocidad. Los resultados de la clasificación no indican que ninguno de los patrones estudiados pueda realizar diagnóstico fiables a 20Hz, sin embargo a 40Hz y 60Hz se obtienen resultados prometedores en todos los casos. Los mejores se obtienen analizando las energías de los paquetes relativos a $3x$ a la velocidad de 60Hz, concretamente para el paquete vecino más cercano al que contiene a la frecuencia $3x$, por lo que este patrón sería candidato a ser el óptimo para diagnóstico. Para este caso, se obtiene un 5 % aproximadamente de falsas alarmas y se detectarían los defectos a partir del nivel D3 con un 99,61 % de fiabilidad.

Finalmente, para los casos de diagnóstico cuando el eje está sano y para defectos a partir del nivel de defecto D3 existen ligeros errores entre la curva POD obtenida mediante este método y la ideal. Sin embargo, esta técnica está enfocada a ser parte de un proceso de monitorización de estado. La consecuencia de que estos errores existan es que, al no tener una diagnóstico con una probabilidad de acierto del 100 % para estos casos, no se podrá estar seguros de su estado real con una sola medida, y habrá que realizar varias para estar seguros. Para los niveles de defecto D1 y D2 hay un error más elevado. Así, el primer nivel de defecto que se detecta con fiabilidad es el D3 (sección afectada del 7,31 %).

7.2. Selección de parámetros locales según los resultados de un estudio global de las señales experimentales

En la sección anterior se proponía un método fiable de detección de fallos a partir del análisis de la energía WPT, seleccionando los parámetros locales óptimos de la energía WPT a través de los resultados de un modelo teórico. Para ello, se realizó un estudio de las energías en la banda de frecuencias $[0,5x]$ para cada caso de velocidad. El patrón seleccionado fue el paquete vecino al que contiene el tercer armónico de la velocidad de giro, $3x$, por ser el que mayores aumentos de energía presentaba cuando aparecía un defecto. Este método ha arrojado resultados de detección muy fiables a la velocidad de 60Hz en el caso experimental estudiado, sin utilizar un sistema de clasificación inteligente.

Sin embargo, en una máquina industrial, las señales obtenidas mediante acelerometría contienen información muy valiosa sobre la totalidad de los elementos de la máquina, por lo que el estudio de otras energías que componen la señal puede proveer información muy interesante. La aparición de un defecto en uno de los elementos de una máquina, como en el caso del eje, puede generar cambios de comportamiento en otros elementos que afecten a la señal de vibración obtenida. También es posible que exista alguna componente de una frecuencia estructural de la máquina que pueda ser un buen indicador de la presencia de un defecto. Por tanto, en esta sección, se pretende comprobar si es posible mejorar los resultados de clasificación teniendo en cuenta también los fenómenos que pueden ocurrir fuera de la banda de frecuencias $[0,5x]$, y que puedan estar relacionados con otros elementos o incluso con frecuencias estructurales de la máquina.

Por tanto, a continuación se muestra un análisis de los paquetes significativos realizando la búsqueda a lo largo de toda la señal (es decir, $[0,3.000\text{Hz}]$). Se escogerán numerosos paquetes como patrones o posibles indicadores de defecto, por lo que es necesario utilizar un sistema clasificador más complejo, ya que sería demasiado laborioso establecer patrones de comportamiento y valores umbral para todos los casos. Debido a ello, en este caso se utilizarán como sistema clasificador redes neuronales artificiales (ANN).

7.2.1. Análisis global de energías de las señales experimentales

Para el análisis sobre las señales experimentales de las bandas de frecuencia más significativas para diagnosis, se selecciona de nuevo el nivel de descomposición 9, para el que cada paquete cubre una banda de frecuencias de aproximadamente 6Hz. Para realizar este estudio, se vuelve a recurrir al estudio de los incrementos de las medias globales de energía WPT para cada grupo de medidas tomadas bajo las mismas condiciones de defecto y de velocidad.

En la sección anterior, se analizaron los incrementos de energía con el aumento del tamaño de defecto para los paquetes relacionados con las frecuencias de fallo obtenidas del modelo teórico. Sin embargo, en este caso se consideran el total de paquetes generados al nivel de descomposición 9 (512 paquetes), analizando los incrementos de energía que se producen al aparecer una fisura, respecto a los datos de eje sano. Debido al elevado número de paquetes a considerar, se establece un método para seleccionar los que presentan las mayores diferencias de energía respecto al eje sano. La metodología empleada es la que se muestra en la figura 7.31, donde el promedio de los valores de energía obtenidos para cada caso de defecto se resta al promedio de eje sano. Del valor absoluto de cada una de las 9 distribuciones obtenidas, se seleccionan los 10 paquetes que presentan los valores máximos.

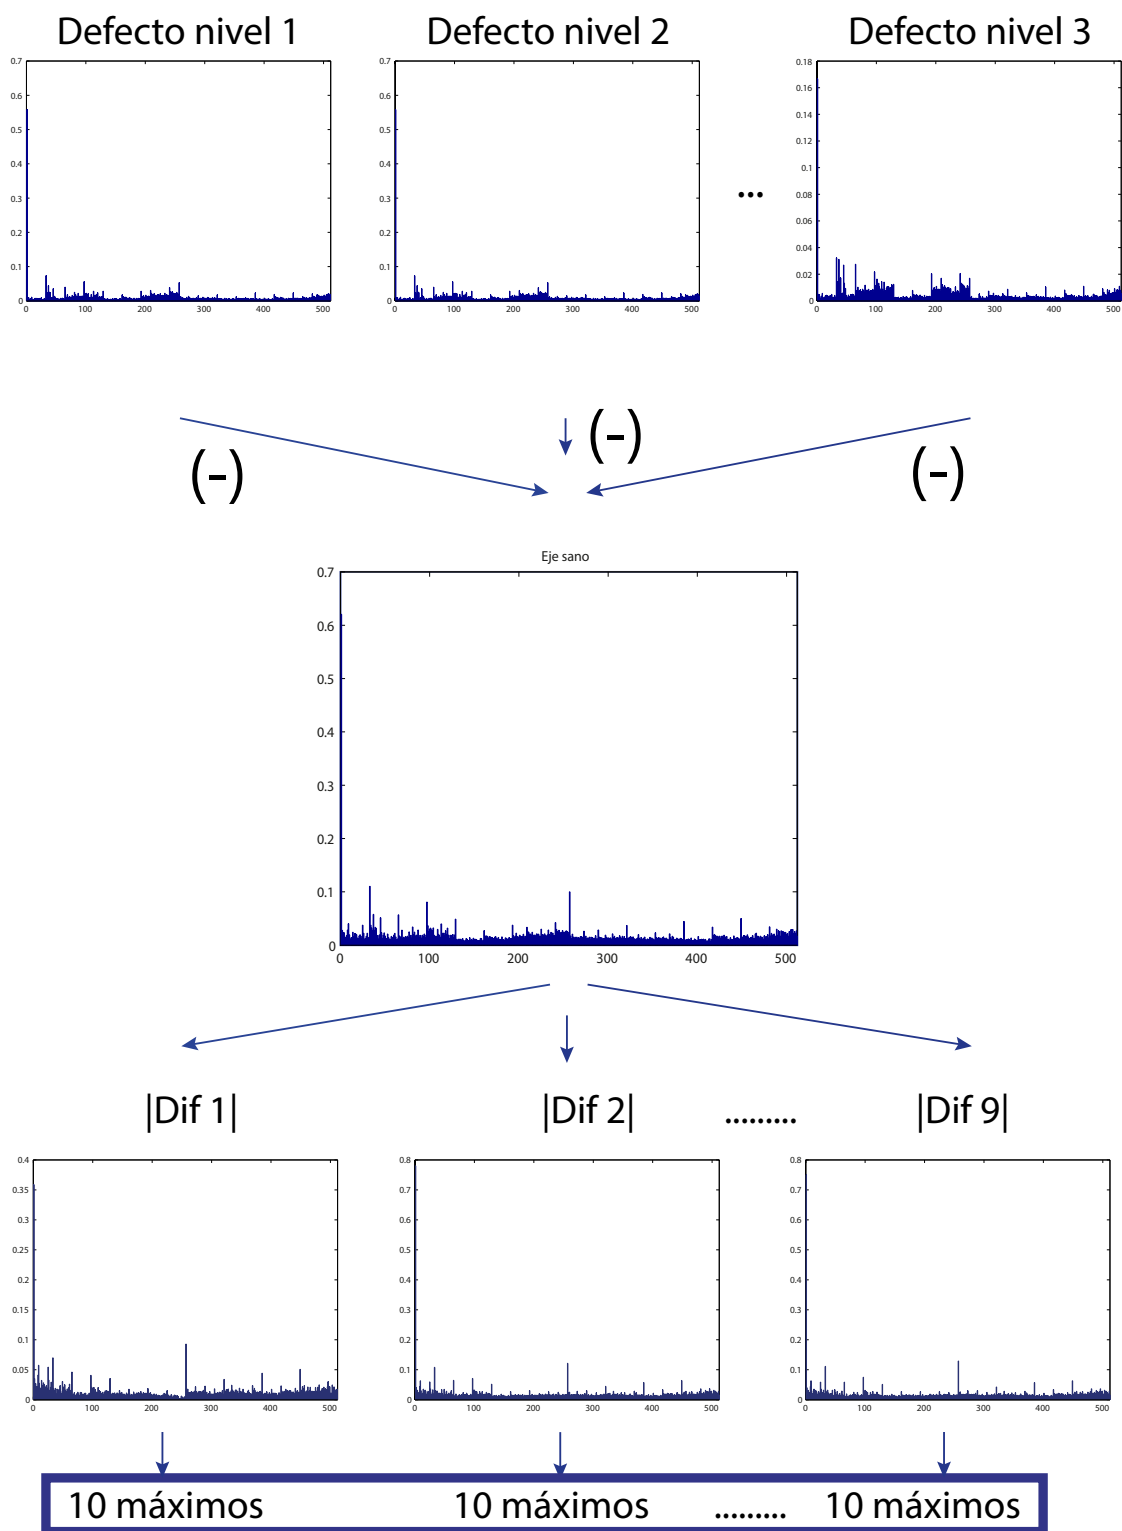


Figura 7.31: Metodología para la selección de los paquetes óptimos para señales experimentales utilizando niveles de descomposición elevados

Así, se podrían obtener hasta 90 paquetes significativos, 10 máximos por cada diferencia obtenida. Sin embargo, como en la mayoría de los casos los paquetes significativos son coincidentes, este número se ve reducido considerablemente.

En las tablas 7.3, 7.4, y 7.5 se muestran las bandas de frecuencia significativas obtenidas después de aplicar este método de selección, para los casos de 20, 40 y 60Hz, ordenadas según la frecuencia en que aparecen.

Se puede observar que, para todos los casos, la mayoría de las bandas de frecuencias cubren múltiplos de 46,88Hz o vecinos cercanos a dichas bandas. Las frecuencias correspondientes aparecen en las tablas relacionadas con esta frecuencia fundamental que se denomina f .

Velocidad	Orden	Banda de frecuencia (Hz)
20Hz	1	369,1-375 (8f)
	2	375-380,9 (8f)
	3	2244,1-2250 (48f)
	4	1494,1-1500 (32f)
	5	87,9-93,8 (2f)
	6	1500-1505,9 (32f)
	7	93,8-99,9 (vecino a 2f)
	8	744,1-750 (16f)
	9	328,1-334 (7f)
	10	29,3-35,2 (2/3f)

Tabla 7.3: Bandas de frecuencia más significativas ordenadas según relevancia, para la velocidad de 20Hz a nivel de descomposición 9

Velocidad	Orden	Banda de frecuencia (Hz)
40Hz	1	1019,5-1025,4 (vecino a 22f)
	2	937,5-943,4 (20f)
	3	978,5-984,4 (21f)
	4	931,6-937,5 (20f)
	5	1013,7-1019,5
	6	972,7-978,5 (vecino a 21f)
	7	984,4-990,2 (21f)
	8	943,4-949,2 (vecino a 20f)
	9	1037,1-1043 (vecino a 22f)
	10	1054,7-1060,5
	11	369,1-375 (8f)
	12	744,1-750 (16f)
	13	386,7-392,6
	14	380,9-386,7 (vecino a 8f)
	15	363,3-369,1 (vecino a 8f)

Tabla 7.4: Bandas de frecuencia más significativas ordenadas según relevancia, para la velocidad de 40Hz a nivel de descomposición 9

Velocidad	Orden	Banda de frecuencia (Hz)
60Hz	1	369,1-375 (8f)
	2	375-380,9 (8f)
	3	187,5-193,4 (4f)
	4	234,4-240,2 (5f)
	5	293-298,8
	6	181,6-187,5 (4f)
	7	240,2-246,1 (vecino 4f)
	8	228,5-234,4 (5f)
	9	351,6-357,4
	10	1500-1505,9 (32f)
	11	1494,1-1500 (32f)
	12	744,1-750 (16f)
	13	978,5-984,4 (vecino a 21f)
	14	984,4-990,2 (21f)
	15	855,5-890,6 (19f)
	16	380,1-386,7 (vecino a 8f)
	17	2244,1-2250 (48f)
	18	363,3-369,1 (vecino a 8f)

Tabla 7.5: Bandas de frecuencia más significativas ordenadas según relevancia, para la velocidad de 60Hz a nivel de descomposición 9

El hecho de que esta frecuencia aparezca como significativa para las tres velocidades de giro, (es decir, que sea independiente de la misma), indica que se corresponde con una frecuencia estructural de la máquina. En el trabajo [111] se realizó un estudio experimental de los modos de vibración del banco de ensayos Rotokit sin el eje montado, y se determinó que la primera frecuencia estructural del banco de ensayos era precisamente de 46,88Hz. Este resultado es muy importante, ya que quiere decir que la aparición de un defecto provoca cambios de energía en frecuencias estructurales de la máquina que no están relacionadas con el eje.

7.2.1.1. Selección de posibles patrones óptimos

Utilizando este método para la selección de los paquetes significativos, en este caso se obtienen multitud de paquetes que pueden ser utilizados como patrones (10 en el caso de 20Hz, 15 en el caso de 40Hz y 18 para el caso de 60Hz) para el nivel de descomposición 9. Además, en este caso, en algunos paquetes se observa que la energía aumenta cuando aparece un defecto, y en otros disminuye. Debido a que los patrones en este caso tienen una estructura compleja, esta cantidad de información no puede ser manejada con el método anterior, y es necesario considerar un sistema de clasificación también más complejo, que sea capaz de aprender los patrones de eje sano y de eje defectuoso correspondientes a un número elevado de paquetes. Las redes neuronales artificiales (ANN) son idóneas para estos casos.

La utilización de las ANN como sistema de clasificación tiene ventajas respecto al método anterior: por un lado no se necesita realizar un análisis por parte de un experto, o tener un conocimiento claro de lo que ocurre con las energías de cada paquete analizado, y por otra parte, dan mayor flexibilidad para automatizar diferentes procesos. Debido a estas ventajas, en

este caso se va a realizar un proceso automatizado para evaluar si sería más adecuado escoger otro nivel de descomposición diferente del 9, utilizado para el análisis de frecuencias significativas.

Se pretende, por tanto, diseñar un proceso automático que optimice las tasas de acierto de la red neuronal, cuya configuración ha de ser optimizada a su vez en cada caso. El objetivo es encontrar, por un lado el nivel de descomposición y por otro lado los parámetros locales óptimos, para obtener los mejores valores de clasificación. Debido a ello, es necesario definir en primer lugar un rango adecuado de estudio para los valores de descomposición.

El máximo valor de nivel de descomposición considerado a priori es el 9, para el que se generan 512 paquetes que cubren una banda de frecuencias de aproximadamente 6Hz, y no se considera necesario un refinamiento mayor. Además, como se ha observado, los efectos de una fisura, en términos de energía, se comparten entre paquetes vecinos, por lo que la lógica sería la de utilizar niveles de descomposición menores, para obtener menos paquetes y así evitar este fenómeno. El valor mínimo considerado para el nivel de descomposición es el de 2. Se toma este valor ya que, utilizando el nivel de descomposición 1 con únicamente dos paquetes de energía, los entrenamientos finalizan en todos los casos debido a que se alcanza el número máximo de neuronas en la capa oculta impuesto (700 neuronas), y no se obtiene un valor de error MSE menor al objetivo. El coste computacional, además, se dispara.

Para niveles de descomposición bajos, debido al reducido número de paquetes generado, no es posible realizar una selección de los mismos mediante el método descrito, por lo que se considera directamente realizar entrenamientos con todos los paquetes. Sin embargo, para niveles de descomposición altos, se observan dos posibilidades: entrenar las redes neuronales con una selección de paquetes, o realizar los entrenamientos con el total de paquetes de que se dispone. Para tomar esta decisión, se realizaron los entrenamientos de las dos maneras planteadas para los niveles de descomposición desde el 5 hasta el 9. En los entrenamientos para los que se utilizaban todos los paquetes generados se observó que, a partir del nivel 6, las tasas de acierto eran bastante inferiores que utilizando la selección de paquetes, y el coste computacional también era considerablemente mayor. Por esta razón, con el fin de encontrar la disposición óptima de los patrones, hasta el nivel de descomposición 5 se utilizarán como patrones de entrada todos los valores de energía de la señal, y para niveles de descomposición más altos (a partir de 5), se realizará una selección de los mismos mediante el proceso descrito en la sección anterior, según se muestra en la tabla 7.6,.

Nivel de descomposición	Patrones de entrada a las redes
Del 2 al 5	Todos los paquetes
Del 6 al 9	Combinación de los 10 máximos de cada condición

Tabla 7.6: Selección de los patrones de entrada según el nivel de descomposición

Una vez obtenidos todos los patrones, y seleccionada la disposición de los mismos de cara a las redes, se procede al diseño de las mismas.

7.2.2. Diseño del sistema de clasificación: redes neuronales RBF

En la sección 5.2.1 se explicó la metodología utilizada para el diseño de las redes neuronales, que consistían en los siguientes pasos:

- Selección de los patrones de entrada, lo que determinará el número de neuronas en la capa de entrada.
- Selección del número posible de salidas, lo que determina el número de neuronas en la capa de salida.
- Selección del valor máximo admisible para el error MSE (*goal*). Se comenzará para todos los casos por el valor de 0,2, ya que es un valor adecuado para obtener buenos resultados sin excederse en coste computacional, (una vez diseñada la red óptima se refinarán los resultados utilizando un *goal* de 0,1).
- Barrido por diferentes valores de *spread*, en el rango [0,2-2]. Será seleccionado el valor de *spread* que ofrezca los resultados óptimos, tanto atendiendo a maximizar la tasa de acierto como a minimizar el número de neuronas en la capa oculta.

Se han seleccionado varias disposiciones de paquetes que serán las entradas para diferentes entrenamientos cuya finalidad es encontrar la configuración óptima. Para realizar los entrenamientos, en este caso no se utilizarán promedios de los patrones, ya que las redes neuronales tienden a un mejor comportamiento cuanto mayor es el número de datos con los que entrenan. Por otra parte, en este caso, las curvas POD se obtendrán directamente de los porcentajes de acierto generados de cada red neuronal. Por esta razón, interesa tener un elevado número de datos de clasificación, para que estadísticamente se obtengan datos representativos.

El siguiente paso es seleccionar las posibles salidas del sistema de clasificación. La primera opción considerada es la de utilizar una red con 10 salidas o posibles diagnósticos (10 neuronas de salida), es decir, una por cada condición estudiada (eje sano y cada uno de los 9 niveles de defecto examinados). Sin embargo, el coste computacional es elevado, y además se obtienen peores tasas de acierto que utilizando únicamente dos salidas. Por tanto, la configuración seleccionada para las salidas es de dos neuronas y dos posibles diagnósticos: si el eje está sano o defectuoso.

Una vez fijado el valor de error máximo (MSE) a 0,2 como primera aproximación, para cada nivel de descomposición y velocidad se entrenan 19 redes neuronales distintas con 19 valores diferentes de *spread*. El valor de *spread* que ofrece los resultados óptimos para cada caso, tanto atendiendo a maximizar la tasa de acierto como a minimizar el número de neuronas en la capa oculta, es el seleccionado, de acuerdo el ejemplo mostrado en la figura 5.5, en la sección 5.2.1. De esta manera, en total se realizan 456 entrenamientos.

Además de estos aspectos que atañen al diseño y entrenamiento de una RBF, hay que hacer algunas consideraciones respecto a los patrones de entrada. El entrenamiento de una red neuronal, viene acompañado de una fase posterior que es la de validación, para la que se utilizan datos que no fueron utilizados para el entrenamiento con el fin de comprobar la fiabilidad del mismo. De esta manera, hay que decidir el número de datos elegidos para cada tarea. Además, hay que tener en cuenta que es conveniente normalizar los valores numéricos de la entrada de la red, ya que esto incrementa la estabilidad de los procesos de entrenamiento y prueba [112].

En la tabla 7.7, se muestran los parámetros comunes para los entrenamientos de todas las redes entrenadas.

Normalización de valores de entrada	En $[-1;1]$	
Tipo de aprendizaje	Supervisado	
Número de salidas	2	
Normalización de los valores de salida	$[-1,1]$	
Distribución de datos de entrada	Training	75 %
	Test	25 %
Criterio de parada	<i>Goal</i>	0,1-0,2
	Neuronas en la capa oculta	700
<i>Spread</i>	0,2-2	

Tabla 7.7: Parámetros de diseño de las redes RBF

7.2.3. Resultados de la metodología de selección de parámetros locales según los datos experimentales

En la presente sección se procede a detallar los resultados obtenidos mediante el uso de las redes neuronales RBF. Por una parte se examinarán tanto los valores de tasas de acierto globales de las redes, como el número de neuronas en la capa oculta frente al nivel de descomposición escogido. Por otra parte, y análogamente al capítulo anterior, los resultados de clasificación de las redes se presentarán en forma de curvas POD, de tal manera que los resultados de clasificación de las redes se desglosan para cada condición de eje examinada. Para generar las curvas POD, se utilizan los datos de validación de la red, es decir, los resultados de clasificación del 25 % de los datos que no fueron utilizados para el entrenamiento y se reservaron para el test.

La figura 7.32 presenta los resultados obtenidos de tasas de acierto global de las redes y número de neuronas, respectivamente, en función del nivel de descomposición utilizado, (y de los patrones de entrada utilizados) a la velocidad de 20Hz.




Figura 7.32: Selección del valor de descomposición óptimo a 20Hz (a) Tasas de acierto global en función del nivel de descomposición (b) Número de neuronas en la capa oculta

Se puede concluir que, a esta velocidad, salvo el nivel de descomposición 2, que tiene un coste computacional bastante más elevado que el resto, los demás ofrecen resultados muy similares y

satisfactorios, tanto de tasas de acierto como de número de neuronas creadas en la capa oculta.

En las figuras 7.33 y 7.34 se muestran los resultados de probabilidades de detección para los niveles de descomposición bajos (2-5), donde se utilizan como patrones de entrada todos los paquetes de energía obtenidos, y altos (6-9), donde se realiza una selección de los mismos, respectivamente. Las curvas POD en este caso, se generan a partir del desglose de la tasa de acierto global para cada condición del eje, para los datos reservados para la validación de la red.

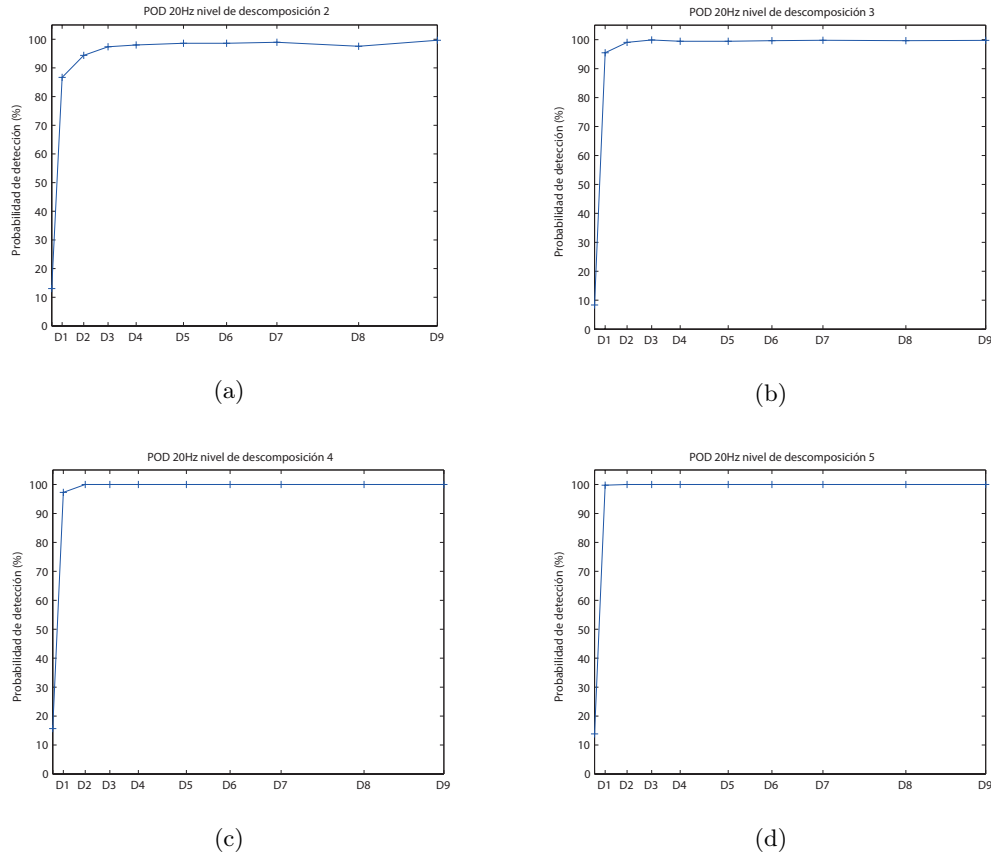


Figura 7.33: PODs obtenidas de las redes neuronales a 20Hz para niveles de descomposición bajos (a) Nivel de descomposición 2 (b) Nivel de descomposición 3 (c) Nivel de descomposición 4 (d) Nivel de descomposición 5

Para los niveles de descomposición bajos, se puede observar que el caso óptimo es el de nivel de descomposición 5, obteniendo casi un 100 % de probabilidad de detección de defectos incluso del nivel 1, el tamaño más pequeño analizado. Sin embargo, como se puede comprobar, existe casi un 15 % de falsas alarmas. En el caso de niveles de descomposición altos, parece que los resultados son bastante similares entre sí, aunque los peores resultados se observan para el caso de nivel de descomposición 9, donde las bandas de frecuencia son más finas. A niveles de descomposición altos, ningún resultado mejora el que se obtiene utilizando descomposición 5.

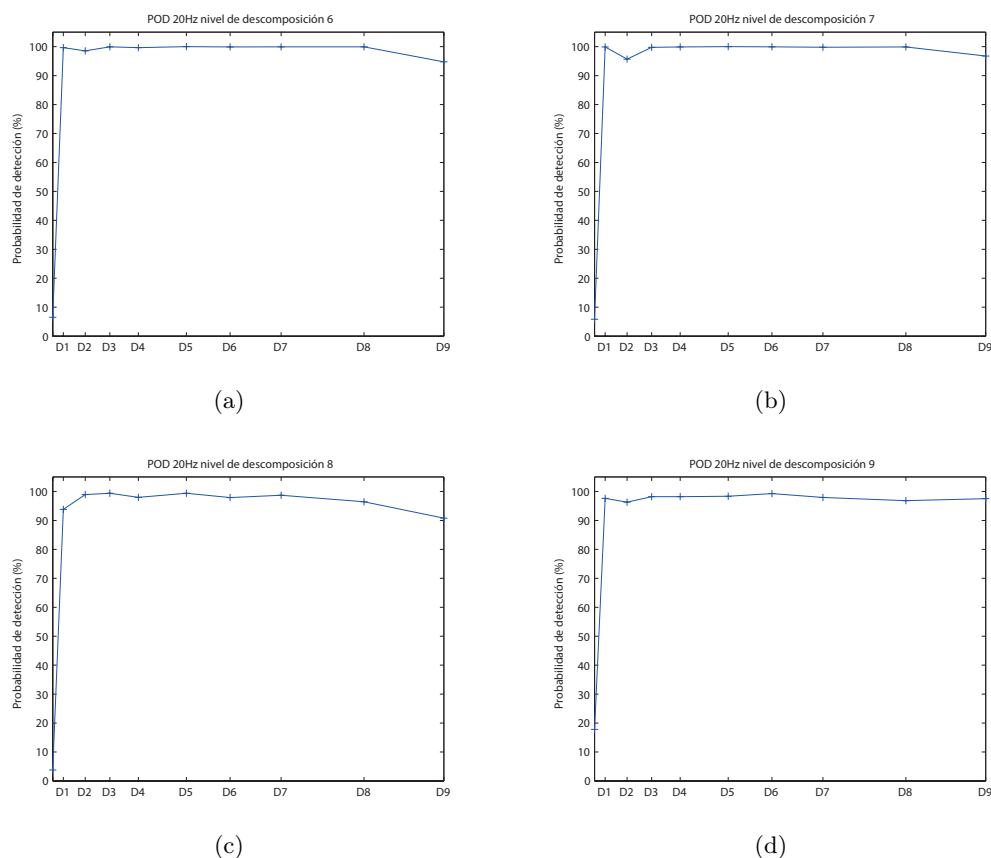


Figura 7.34: PODs obtenidas de las redes neuronales a 20Hz para niveles de descomposición altos (a) Nivel de descomposición 6 (b) Nivel de descomposición 7 (c) Nivel de descomposición 8 (d) Nivel de descomposición 9

Una vez seleccionado el nivel de descomposición 5 como el óptimo, se pasa a entrenar la misma red pero en este caso utilizando un valor de *goal* de 0,1. Al reducir el error admisible para los entrenamientos, se conseguirán tasas de acierto más altas, aunque también se incrementará el coste computacional. En la figura 7.35 se pueden observar los resultados de POD obtenidos con esta red, que presenta un valor bastante más reducido de falsas alarmas, y ofrece diagnóstico muy fiable con 92 neuronas en la capa oculta.

En el caso de la velocidad de 40Hz, se observan diferencias apreciables entre los resultados obtenidos a niveles de descomposición altos y bajos. A niveles de descomposición altos se llega a tener una tasa de falsas alarmas de hasta el 30 %. De esta manera, aunque no se observan grandes diferencias entre los niveles de descomposición 3,4 y 5, parece ser que el valor óptimo tanto para la tasa de acierto como para el número de neuronas es nuevamente el 5. En la figura 7.36 se pueden observar las tasas de acierto obtenidas para una red entrenada con todos los valores de energía obtenidos a nivel de descomposición 5 y un valor máximo admisible de error MSE (*goal*) de 0,1. Esta red, que cuenta con 142 neuronas en la capa oculta, ofrece resultados de clasificación bastante similares a los obtenidos en el caso de 20Hz.

En los resultados del estudio del nivel de descomposición óptimo a la velocidad de 60Hz se han observado grandes diferencias entre los niveles de descomposición altos y bajos, al igual que para el caso de 40Hz. Para altos valores de nivel de descomposición, utilizando como patrones de entrada




Figura 7.35: POD a nivel de descomposición 5 y *goal* 0,1 a 20Hz




Figura 7.36: POD a nivel de descomposición 5 y *goal* 0,1 a 40Hz

los paquetes significativos seleccionados, las diagnosis no son fiables, ya que el número de falsas alarmas es muy elevado. Entre los resultados obtenidos con valores de niveles de descomposición bajos 3, 4 y 5, utilizando como patrones de entrada todas las energías, no se aprecian notables diferencias pero el valor óptimo vuelve a ser el de 5. Se concluye, también para este caso, que la utilización de todos los paquetes de energía obtenidos a niveles de descomposición bajos ofrece mejores resultados. En la figura 7.37 se pueden observar las tasas de acierto obtenidas para la red neuronal en el caso de 60Hz, utilizando los datos de nivel de descomposición 5, y con un valor de *goal* de 0,1. Esta red cuenta con el menor número de neuronas en la capa oculta entre todas las velocidades estudiadas, solamente 45. Aunque los resultados de clasificación son bastante buenos

en todos los casos, en este se observa el menor porcentaje de falsas alarmas que es solamente del 1,77 %. Por tanto, la red que utiliza los datos correspondientes a la velocidad de 60Hz es la que ofrece los mejores resultados.




Figura 7.37: POD a nivel de descomposición 5 y *goal* 0,1 a 60Hz

7.2.4. Resumen de la metodología de selección de parámetros locales según los resultados experimentales

En este capítulo, en primer lugar se ha realizado un estudio de los paquetes o bandas de frecuencia significativas por sufrir mayores variaciones en la energía cuando aparece un defecto. De este estudio, realizado a nivel de descomposición 9, se ha concluido que los mayores cambios en la energía aparecen en armónicos de la frecuencia 46,88Hz, que resulta ser una frecuencia estructural del banco de ensayos utilizado, Rotokit. Aunque a las diferentes velocidades de ensayo aparecen siempre armónicos de esta frecuencia fundamental de la máquina, los armónicos son diferentes en todos los casos, aunque algunos se repiten. Una conclusión fundamental de este estudio es que la aparición de un defecto en el eje provoca cambios en la respuesta emitida de otros elementos del banco. Estos cambios se pueden utilizar para diagnosticar defectos en el eje.

Posteriormente, con el fin de concluir qué nivel de descomposición, y qué patrones de entrada son los más adecuados para la detección de fallos en el eje de esta máquina concreta, se recurre a sistemas de clasificación inteligente, en este caso redes neuronales con arquitectura RBF. El nivel de descomposición y los patrones de entrada se seleccionarán a través de un proceso automático que escogerá los valores que arrojen los mejores resultados de clasificación de las redes neuronales.

Se han considerado diferentes entradas para el entrenamiento de los sistemas de clasificación atendiendo al nivel de descomposición analizado. Para niveles de descomposición bajos se han utilizado todos los niveles de energía generados como patrones de entrada, y a niveles de descomposición altos, se han seleccionado los paquetes más significativos, ya que previamente se ha comprobado que el uso de todos los paquetes de energía a niveles de descomposición altos aumenta el coste computacional sin mejorar (sino todo lo contrario) las tasas de acierto. Esta diferencia permite, además, conocer si las clasificaciones se realizan de manera más adecuada

cuando se utiliza la información relativa a toda la señal, o si por el contrario es más conveniente refinar en las bandas de frecuencia óptimas.

Para todos los casos de velocidad, parece que los resultados más adecuados se obtienen a niveles de descomposición bajos, utilizando la información relativa a toda la señal, y concretamente a nivel de descomposición 5. A niveles de descomposición altos, se ha observado que los resultados son poco fiables, ya que en la mayoría de los casos existe un número elevado de falsas alarmas. Esto permite extraer como conclusión que la aparición de un defecto afecta a toda la señal, y no a bandas de frecuencia estrechas: las redes neuronales funcionan mejor cuando se les proporciona como entrada información relativa a toda la señal que cuando solamente se les ofrece información de los paquetes más significativos.

Por tanto se puede afirmar que, para todos los casos de velocidad de giro, es posible realizar una diagnosis fiable utilizando el total de los 32 valores de energía generados utilizando el nivel de descomposición 5, mediante una ANN con arquitectura RBF. Sin embargo, se observa que según aumenta la velocidad de giro, el número de falsas alarmas se reduce. Además, la red obtenida a 60Hz es la que menor coste computacional implica, ya que cuenta con solamente 45 neuronas. Por tanto se puede afirmar que los resultados óptimos se obtienen de nuevo a 60Hz. Con esta red neuronal se pueden detectar defectos desde el nivel 1 (1,36 % de la sección) con una tasa de acierto superior al 95 %, y defectos mayores que este con prácticamente un 100 % de fiabilidad. El porcentaje de falsas alarmas es tan solo el 1,77 %.

7.3. Comparativa de resultados y selección de la técnica óptima

Para cada método de los dos presentados en las secciones anteriores, se ha seleccionado una curva POD óptima. Ambas son obtenidas para la velocidad de 60Hz, por lo que es posible concluir que al aumentar la velocidad, mejoran los resultados de diagnosis. En la figura 7.38, se pueden observar ambas.

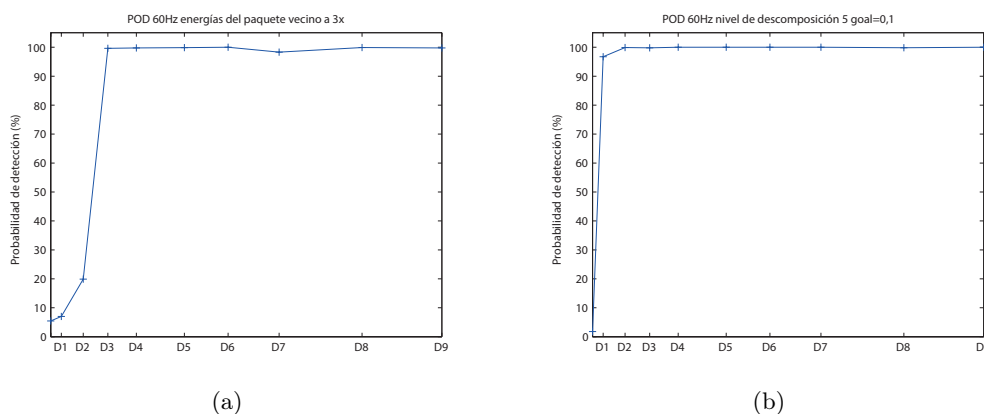


Figura 7.38: Comparación de las curvas POD óptimas obtenidas por cada método (a) POD obtenida utilizando la energía del paquete vecino al 3x a nivel de descomposición 9 a la velocidad de 60Hz, utilizando como clasificador el método de señal de respuesta (b) POD obtenida utilizando todos los paquetes de energía obtenidos a nivel de descomposición 5 a la velocidad de 60Hz, utilizando como clasificador una red neuronal RBF.

A la vista de la figura es posible determinar que los dos métodos propuestos ofrecen resultados

de clasificación muy satisfactorios. Sin embargo, el uso de todas las energías de la señal mediante WPT a nivel de descomposición 5 como patrón, combinado con las redes neuronales, ofrece mejores resultados de detección que el uso de las energías relativas al tercer armónico de la velocidad de giro, ya que en el primer caso es posible diagnosticar con gran precisión defectos desde el nivel 1, cuando en el otro método se detectan a partir del nivel 3. Cabe destacar que, los resultados de curvas POD del método que utiliza las energías relativas al tercer armónico, utilizan como patrón un promedio de grupos de 100 señales, y aún así los resultados que ofrece tienen mayor error respecto a la curva POD ideal.

En la tabla 7.8, se muestran los resultados de tiempo consumido para obtener un diagnóstico a partir de una señal vibratoria. Ambos resultados se han calculado utilizando el programa Matlab en el mismo ordenador, que se trata de un ordenador Dell Precision T7400, con un sistema operativo Windows 7 Professional, con un procesador Intel Xeon E5410, con una velocidad de 2,33GHz, y una memoria RAM de 8GB.

Método	Tiempo de ejecución(s)
Uso del paquete vecino al tercer armónico (des=9)	1,092
Uso de todos los paquetes (des=5)	0,468

Tabla 7.8: Comparación de tiempos de ejecución de los dos métodos de diagnosis analizados

A la vista de la tabla se puede concluir que ambos métodos tienen un coste computacional bastante reducido. Sin embargo, el método por el cual se seleccionaron los parámetros locales de la señal a partir del estudio de las señales experimentales, además de ofrecer mejores resultados de fiabilidad, ofrece mejores resultados de coste computacional. El método seleccionado tarda menos de la mitad que el anterior, teniendo un tiempo de cálculo desde que se introduce la señal de vibración hasta que se realiza el diagnóstico de 0,468 segundos.

7.4. Aplicación de la metodología propuesta a otros elementos mecánicos rotativos

Con el fin de comprobar si la metodología propuesta en este trabajo se puede utilizar para otro tipo de elementos mecánicos, se ha aplicado para diagnosticar rodamientos utilizando señales vibratorias.

Los datos de rodamientos utilizados en este trabajo, se tomaron para la realización de la Tesis Doctoral de Omar Lara, [4]. Las señales vibratorias fueron obtenidas de rodamientos en cuatro condiciones de defecto diferentes: rodamiento sano, con defecto en pista interna, en bola, y en pista externa. Todos los defectos evaluados eran incipientes y las velocidades de ensayo fueron 10Hz, 20Hz y 30Hz.

La aplicación de la metodología global propuesta al caso de rodamientos se puede encontrar detallado en el apéndice C.

El análisis de las frecuencias teóricas de fallo no ofreció buenos resultados de diagnóstico, sin embargo, la aplicación de la segunda metodología estudiando las energías WPT de la señal completa permitió establecer un método de diagnosis fiable. En este caso, los mejores resultados se obtuvieron utilizando los 16 paquetes de energía obtenidos a nivel de descomposición 4, utilizando nuevamente una red neuronal con arquitectura RBF con cuatro posibles salidas correspondientes a las cuatro condiciones diferentes de defecto. Los resultados de clasificación se pueden observar

en la figura 7.39.

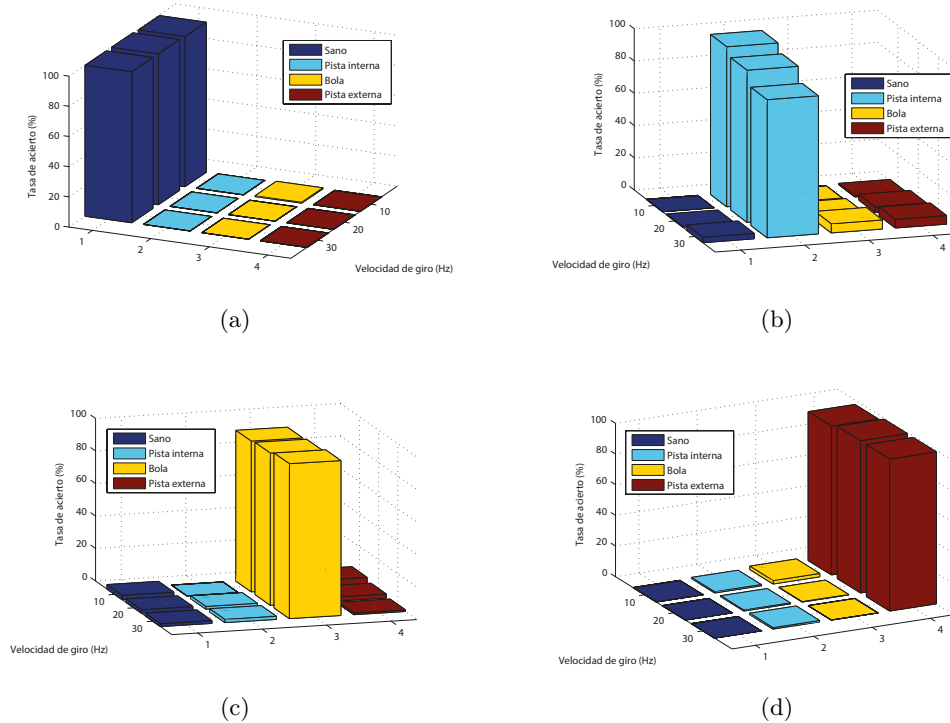


Figura 7.39: Tasa de acierto (%) para las tres redes entrenadas a las distintas velocidades (Hz) (a) Clasificación de rodamiento sano (b) Clasificación de un rodamiento con defecto en pista interna (c) Clasificación de un rodamiento con defecto en bola (d) Clasificación de un rodamiento con defecto en pista externa

Los resultados fueron buenos a todas las velocidades, pero los óptimos se obtuvieron a la velocidad intermedia de las analizadas, la de 20Hz. A esta velocidad se obtiene un sistema de clasificación con tasas de acierto muy altas, con cero falsas alarmas y con menos del 2% de probabilidad de no detección de un defecto incipiente. La localización de los fallos, además, es muy precisa.

Capítulo 8

Conclusiones y futuros desarrollos

8.1. Conclusiones

En la presente Tesis Doctoral se ha desarrollado una metodología general, que permite el establecimiento y validación de una técnica de diagnóstico óptima para un elemento mecánico rotativo integrado en una máquina, basándose en el análisis de señales vibratorias obtenidas durante el funcionamiento de la misma. El trabajo principal se ha centrado en la defectología de ejes, y además, la metodología general desarrollada se ha aplicado también a rodamientos, consiguiendo con éxito tanto el objetivo general, como los objetivos específicos.

La metodología general llevada a cabo ha seguido los pasos que se detallan a continuación con las correspondientes conclusiones obtenidas en cada caso.

Respecto al sistema experimental:

- Desarrollo de un procedimiento experimental que permite extraer las señales vibratorias representativas de cada condición de estudio, estableciendo claramente las mismas. En este caso, las condiciones estudiadas han sido la de eje sano y 9 niveles diferentes de defectos transversales localizados en la posición central del mismo.
- Obtención de un número de señales estadísticamente representativo de cada condición de estudio. Estas medidas, además, se han realizado a tres niveles de velocidad distintos: 20, 40 y 60Hz. El elevado número de señales obtenidas, (aproximadamente 60.000), dificulta el tratamiento de las mismas, pero garantizan la calidad de la información.

Respecto a la selección de patrones y sistema de clasificación:

- Selección de los posibles patrones válidos para la diagnosis. Se ha observado que, para todos los casos estudiados, los valores de la energía de la señal vibratoria obtenida mediante WPT son un buen indicador de defecto, ya que ciertos paquetes experimentan cambios sustanciales con su aparición y crecimiento. La utilización de este patrón facilita la automatización de la selección de los paquetes indicadores de defecto.
- Análisis de las frecuencias teóricas de fallo. Para algunos elementos mecánicos, como los rodamientos, éstas son bien conocidas. Sin embargo en otros casos, como el de ejes, no hay un consenso en la bibliografía sobre cuáles son las frecuencias más afectadas cuando

aparece un defecto. Por tanto, se ha recurrido al desarrollo de un modelo analítico para generar señales vibratorias teóricas para eje sano y eje dañado. El modelo ha sido realizado en *Matlab*[®] y *Simulink*[®], basado en el modelo de rotor Jeffcott al que se ha incluido una función de respiro, con el fin de reproducir el sistema experimental. Los resultados obtenidos se han utilizado para seleccionar las frecuencias más afectadas cuando aparece un defecto, que son la velocidad de giro, 1x, sus armónicos 2x y 3x, y la energía total de la señal. Además, los paquetes vecinos a los que contienen las frecuencias teóricas de fallo, también son buenos indicadores de defecto, porque los efectos de una fisura en términos de energía se comparten. Para otro tipo de elementos rotativos, será necesario realizar el correspondiente estudio.

- Análisis de las frecuencias teóricas de fallo en las señales experimentales para ejes. Los efectos de las fisuras observados en el modelo teórico se buscan también en las señales experimentales. Las consecuencias del defecto encontradas en la frecuencia 3x y en la energía total también se muestran claramente en las señales obtenidas del banco de ensayos. Sin embargo, los efectos teóricos producidos sobre las frecuencias 1x y 2x se ven enmascarados en la práctica. Se ha concluido, además, que dichas energías aumentan de forma exponencial con el tamaño del defecto. Una vez encontrados los patrones indicadores de defecto para las señales experimentales, se ha diseñado un clasificador óptimo para cada caso, observando una mejora clara de los resultados cuando aumenta la velocidad. Así, los mejores resultados se obtienen a 60Hz, velocidad a la cual se puede establecer una diagnosis fiable con un número reducido de falsas alarmas, diagnosticando casi con un 100 % de fiabilidad defectos superiores al 7,31 % sección afectada.
- Análisis de las energías de la señal completa para ejes. Ya que algunos de los efectos teóricos de un defecto en una máquina industrial se pueden ver enmascarados por ruido u otros fenómenos indeseados, se considera realizar un estudio más profundo teniendo en cuenta la totalidad de la señal. Se extrajeron las bandas de frecuencia que presentaban mayores diferencias entre las energías de eje sano y de eje defectuoso. Para todos los casos de velocidad estudiados, siempre aparecían como significativas bandas de frecuencia relacionadas con armónicos de 46,88Hz, primera frecuencia estructural de la máquina (obtenida experimentalmente con el eje desmontado). Por tanto se puede concluir que, un defecto presente en un elemento rotativo puede producir cambios en la respuesta dinámica en frecuencias relacionadas con otros elementos de la máquina. Utilizando ANN con arquitectura RBF, se realizó un análisis tanto del nivel de descomposición utilizado para calcular las energías WPT, como de las posibles combinaciones de los diferentes paquetes significativos. Los mejores resultados de clasificación, tanto en términos de fiabilidad como de coste computacional, se obtuvieron entrenando las redes neuronales utilizando los 32 paquetes de energía obtenidos a nivel de descomposición 5. Los resultados fueron desglosados para obtener las curvas *Probability of Detection*, probabilidad de detección (POD), mostrando que a todas las velocidades de giro las tasas de acierto son muy satisfactorias. Sin embargo, los mejores resultados se obtuvieron de nuevo a la velocidad más alta, 60Hz. En este caso, se pueden detectar defectos desde el nivel 1 (1,36 % de sección afectada) con una fiabilidad cercana al 100 %, con un porcentaje de falsas alarmas de sólo el 1,77 %.

Respecto a la aplicación a elementos mecánicos rotativos:

Con el fin de comprobar la generalidad de la metodología propuesta, se ha realizado una aplicación directa al caso de rodamientos, elemento rotativo de gran importancia del sistema de apoyo.

- La metodología se aplicó con éxito en un tiempo reducido, resultando que el número de falsas alarmas fue muy cercano a cero, y las tasas de acierto rondaron el 98 %, lo que indica que el sistema es capaz no sólo de detectar defectos incipientes en los rodamientos, sino además de localizarlos (ver apéndice C).
- Tanto para el caso de ejes como para el de rodamientos, los mejores resultados de clasificación se han obtenido utilizando información relativa a la energía de la señal correspondiente a una banda de frecuencias ancha (concretamente $[0,3.000\text{Hz}]$), y utilizando niveles de descomposición entre 3 y 5 para la WPT. Se observó que, la aparición de un defecto en un elemento de una máquina, provoca cambios en la energía de la señal en paquetes relativos a frecuencias estructurales y sus armónicos, razón por la cual se obtienen mejores resultados de diagnosis analizando una banda de frecuencias ancha.

8.2. Futuros desarrollos

Los futuros desarrollos o posibles líneas de investigación que se abren con esta Tesis Doctoral son:

- El análisis y optimización de la transformada de Hilbert-Huang como posible patrón, para examinar si pudiera ofrecer mejores resultados que la transformada Wavelet.
- La utilización de otros métodos de clasificación para el proceso de diagnosis, como algoritmos genéticos, máquinas de soporte vectorial o lógica borrosa. Aunque las redes neuronales han ofrecido muy buenos resultados, sería conveniente explorar todo el campo disponible de sistemas de clasificación con el fin de verificar si alguno de ellos pudiera arrojar mejores resultados.
- El análisis de un rango más amplio de defectos. El método de diagnosis propuesto en el caso de ejes detecta incluso el defecto más pequeño analizado (D1). Sería muy interesante analizar defectos más pequeños para encontrar cuál es el defecto más pequeño que puede ser detectado con fiabilidad por este método.
- El análisis de defectos que se encuentren otras posiciones del eje. Este estudio ayudaría a determinar si la misma red neuronal sería capaz de identificarlos o sería necesario realizar nuevos entrenamientos.
- Realizar un estudio sobre la influencia de la carga. El eje analizado en este trabajo no se encuentra cargado. Cabe esperar que la aplicación de una carga amplifique fenómenos como el respiro, mejorando así los resultados de diagnosis. Sin embargo, sería conveniente comprobar experimentalmente este hecho.
- Ampliar el rango de velocidades estudiado. De esta manera, se podría observar cuál es el valor de velocidad óptima para la clasificación.

- El análisis de la vibración en otras direcciones diferentes de la vertical, para comprobar si los resultados obtenidos pueden ser mejorados.
- La integración de la metodología general propuesta en una interfaz gráfica que permitiera la diagnosis en tiempo real para un operario no experto.
- La validación de la metodología general propuesta sobre otro tipo de elementos mecánicos como engranajes y cajas de cambios fisurados.
- La integración de la diagnosis de varios elementos mecánicos en un único sistema clasificador que permita diagnosticar una maquinaria completa, distinguiendo posibles fallos entre sus elementos.

Conclusions and future work

Conclusions

In the present Doctoral Thesis, it has been developed a general methodology that allows establishing and validating an optimal diagnosis technique for a specific rotating element installed in a machine, based in the analysis of vibratory signals obtained during working. The main work is focused in shafts defectology, however the methodology has been also applied to bearings, achieving successfully the general and specific objectives.

The general methodology is composed by the steps detailed forward, joined with the specific conclusions obtained in each case.

Regarding the experimental system:

- Development of an optimal experimental methodology that allows the extraction of vibratory signals representative of each condition studied. In this case, the different conditions analysed have been healthy axle and nine different crack levels of transversal defects, located in the middle of it.
- Obtaining a statistical representative number of signals for each condition studied. These measurements have been taken at three different rotation speeds: 20Hz, 40Hz and 60Hz. The large number of signals obtained (around 60000) provide difficulties to its treatment; however they warrantee the quality of the information.

Regarding the pattern selection and the classification system:

- Selection of the possible patterns valid for diagnosis. It has been observed that, for all the studied cases, the values of energy of the vibratory signal obtained by means of the WPT, are a good indicator of the presence of a crack. Certain packets experiment significant changes of energy when a crack appears and grows. The use of this pattern facilitates the automating of the selection of the packets indicators of crack.
- Analysis of the theoretical failure frequencies. For some mechanical elements, as bearings, the values of these frequencies are well known, however in the case of shafts there are not consensus in the bibliography about the frequencies that are best indicators of crack. To help to this analysis, an analytical model has been developed to generate vibratory signal corresponding to healthy and cracked shafts. The model has been carried out using *Matlab*[®] and *Simulink*[®], based in the Jeffcott rotor using a breathing function, reproducing the conditions of the shaft installed in the rig. The results obtained have been used to

select the most affected frequencies when a crack appears, that are the frequency related to the rotating speed, $1x$, its harmonics $2x$ and $3x$, and the total energy of the signal. Besides, the packets neighbors to those who hold the theoretical failure frequencies are also good indicators of crack. This phenomenon occurs because the effects of a crack, in terms of energy, are shared between them.

- Analysis of the theoretical failure frequencies on the experimental signals. The crack effects found in the theoretical model are searched for in the vibratory signals obtained from the rig. The consequences of the crack observed in the frequency $3x$ and in the total energy are clearly shown also in the experimental signals. However, the effects over the frequencies $1x$ and $2x$ are hidden in the practice. It has been concluded that the related energies increase exponentially with the crack size. Once some patterns or energies that are considered indicators of crack are found for the experimental case, an optimal classifier system is designed for each case. The classification results are better as the rotation speed increases. Hence, the best results are obtained at the speed of 60Hz, obtaining a very low value of false positives and detecting with almost a 100 % of reliability defects of size over 7.31 % of damaged section.
- Analysis of the energies of the whole signal for axles. As some of the theoretical effects of a crack are hidden in the experimental cases, a deeper study is considered analyzing the whole signal. Specifically, the frequency bands that presented larger differences between the energy of healthy and cracked axles were searched for. For all the rotation speeds tested, there were always significant frequency bands related to harmonics of 46.88Hz, which is the first structural frequency of the rig (obtained experimentally without the axle installed on it). Hence, it can be concluded that a defect present in one rotating element, can cause changes in the dynamic response in frequencies related to other elements of the machine. By means of neural networks with RBF architecture, an analysis of both the decomposition level of the WPT energies and different possibilities of combinations of the significant packets was carried out. The best classification results, in terms of reliability and computational cost, were obtained training the neural networks with the 32 packets of energy obtained at the decomposition level of 5. The classification results were broken down to obtain POD curves showing that at all the speeds tested, the success rates were very satisfactory. Nevertheless, again the best results were obtained at the higher speed, 60Hz. In this case, defects since the level 1 (1.36 % of damaged section) can be detected with almost a 100 % of reliability, with a false alarms percentage of only 1.77 %.

Regarding the application to mechanical rotating elements:

With the aim of proving the possible generalization of the proposed methodology, it has been also applied to diagnose bearings, rotating elements of great importance for the support system.

- The methodology has been applied successfully in a short period of time, resulting that the false alarms value is very close to zero, and the success rates are around 98 %. The system is not only capable to detect incipient defects in the bearings, but also is able to locate them with high reliability.
- Both for the case of axles and for bearings, the best classification results have been obtained using information related to the energies of the signal in a wide frequency band (specifically [0,3.000Hz]), and using decomposition levels between 3 and 5 for the WPT. It has been

observed that, when a crack appears, there are important changes in the energy of packets related to structural frequencies of the machine and its harmonics, reason why results are better analysing a wider frequency band.

Future work

The future work or possible research lines opened with this Doctoral Thesis are:

- The analysis and optimization of the Hilbert-Huang transform as possible pattern to check if it can offer best diagnosis results than the WT.
- The use of other classification methods as genetic algorithms, support vector machines or fuzzy logic. The artificial neural networks have offered very good results, but it would be convenient to explore the entire field.
- The analysis of a wider range of defects. The diagnosis technique applied in this work for the case of shafts is able to detect with high reliability even first level of crack tested (1.36 % of damaged section). It would be very interesting to test smaller crack sizes to determine which defect is the smallest one that can be detected.
- The analysis of cracks located in other positions of the shaft. This study would help to know if defects located in other positions can be detected with the same neural network or further training is required.
- A study about the load influence. In this work, the shaft tested is not loaded. It can be expected that if a load is applied, the breathing phenomena and other effects can be amplified, so the diagnosis results would be better. Nevertheless, it would be convenient to check it experimentally.
- Increase the range of speeds tested. It would be useful to determine which one is the optimal for classification.
- The analysis of vibration measured in other directions different than the vertical one, to check if the results can be improved.
- The integration of the whole general methodology in a graphical interface that allows the diagnosis in real time for a non expert operator.
- The validation of the general methodology proposed over other kind of mechanical elements as cracked gears.
- The integration of algorithms of diagnosis of several mechanical elements in an unique classification system that allows to determine the status of a complete machine, detecting and distinguishing faults in different elements.

Bibliografía

- [1] N. Bachschmid, P. Pennacchi, and E. Tanzi. *Cracked rotors: A survey on Static and Dynamic Behaviour Including Modelling and Diagnosis*. Springer, 2010.
- [2] W.D. Rummel. Recommended practice for demonstration of non destructive evaluation (NDE) reliability in aircraft parts. *Materials Evaluation*, 40:923–932, 1982.
- [3] S. Cantini and S. Beretta. *Structural reliability assessment of railway axles*. Lucchini RS, 2011.
- [4] O. Lara. *Nuevas metodologías no invasivas de diagnosis de defectos incipientes en rodamientos de bola*. Tesis Doctoral, Universidad Carlos III Madrid, 2007.
- [5] E. Douka, S. Loutridis, and A. Trochidis. Crack identification in beams using wavelet analysis. *International Journal of Solids and Structures*, 40:3557–3569, 2003.
- [6] A.D. Dimarogonas. Dynamic response of cracked rotors. In *General Electric Company, Internal Report, Schenectady, NY*, 1970.
- [7] M. Akgun, T.L. Paez, and F.D. Ju. Transmissibility as a means to diagnose damage in structures. In *Proceedings on the 3rd International Modal Analysis Conference, Orlando, New College, New York, USA*, volume 1, pages 701–707, 1985.
- [8] J.C. García-Prada, C. Castejón, M.J. Gómez, J. Álvarez, A. Moreno, and W. Kappes. Euraxles - WP5: Non-destructive testing (NDT) and verification on the reliability of axles in service. In *17th International Wheelset Congress, Kiev, Ukraine*, 2013.
- [9] N. Bachschmid, P. Penacci, and E. Tanzi. Some remarks on breathing mechanism, on non-linear effects and on slant and helicoidal cracks. *Mechanical Systems and Signal Processing*, 22:879–904, 2012.
- [10] G. Sabnavis, R.G. Kirk, M. Kasarda, and D. Quinn. Cracked shaft detection and diagnostics: a literature review. *The Shock and Vibration Digest*, 36:287–296, 2004.
- [11] C.A. Papadopoulos. The strain energy release approach for modeling cracks in rotors: A state of the art review. *Mechanical Systems and Signal Processing*, 22:763–789, 2008.
- [12] A.S. Sekhar and B.S. Prabhu. Condition monitoring of cracked rotors through transient response. *Mechanisms and Machine Theory*, 33(8):1167–1175, 1998.
- [13] M.A. Al-Shudeifat and E.A. Butcher. New breathing functions for the transverse breathing crack of the cracked rotor system: Approach for critical and subcritical harmonic analysis. *Journal of Sound and Vibration*, 330:526–544, 2011.

- [14] R. Gash. Dynamic behavior of a simple rotor with a cross-sectional crack. In *Institution of Mechanical Engineers Conference, Vibration in Rotating Machinery, Cambridge, UK*, number 178/76, 1976.
- [15] N. Bachschmid and P. Penacci. Crack effects in rotordynamics. *Mechanical Systems and Signal Processing*, 22:761–762, 2008.
- [16] I.W. Mayes and W.G.R. Davies. The vibrational behaviour of a rotating shaft system containing a transverse crack. In *Institution of Mechanical Engineers Conference, Vibration in Rotating Machinery, Cambridge, UK*, number 168/76, 1976.
- [17] R. Gasch. Dynamic behaviour of the laval rotor with a transverse crack. *Mechanical Systems and Signal Processing*, 22:790–804, 2008.
- [18] Z. Kulesza and J.T. Sawicki. Rigid finite element model of a cracked rotor. *Journal of Sound and Vibration*, 331:4145–4169, 2012.
- [19] C. Kumar and V. Rastogi. A brief review on dynamics of a cracked rotor. *International Journal of Rotating Machinery*, 2009.
- [20] J. Páez, M. Wiercigroch, and H. Demrdash. Numerical study of a Jeffcott rotor model with a snubber ring. *Journal of Physics*, 382, 2012.
- [21] E.V. Karpenko, M. Wiercigroch, E.E. Pavlovskaja, and R.D. Neilson. Experimental verification of Jeffcott rotor model with preloaded snubber ring. *Journal of Sound and Vibration*, 298:907–917, 2006.
- [22] Q. Han, J. Zhao, and F. Chu. Dynamics analysis of a geared rotor system considering a slant crack on the shaft. *Journal of Sound and Vibration*, 331:5803–5823, 2012.
- [23] L. Cheng, N. Li, X. Chen, and Z. He. The influence of crack breathing and imbalance orientation angle on the characteristics of the critical speed of a cracked rotor. *Journal of Sound and Vibration*, 330:2031–2048, 2011.
- [24] C. Castejón, J.C. García-Prada, M.J. Gómez, and J. Meneses. Automatic detection of cracked rotors combining multiresolution analysis and artificial neural networks. *Journal of Vibration and Control*, 2014.
- [25] J. Gomez-Mancilla, J. Sinou, and V.R. Nosov. The influence of crack-imbalance orientation and orbital evolution for an extended cracked jeffcott rotor. *Comptes Rendus Mecanique*, 332(12):995–962, 2004.
- [26] A.F.P. Sanderson. The vibration behaviour of a large steam turbine generator during crack propagation through the generator rotor. In *Institution of Mechanical Engineers Conference, Vibrations in Rotating Machinery, Bath, UK*, number 432/102, 1976.
- [27] A.S. Sekhar, A.R. Mohanty, and S. Prabhakar. Vibrations of cracked rotor system: transverse crack versus slant crack. *Journal of Sound and Vibration*, 279:1203–1217, 2005.
- [28] A.D. Dimarogonas. Vibration of cracked structures: a state of the art review. *Engineering Fracture Mechanics*, 55(5):831–857, 1996.
- [29] S. Mallat. *A wavelet tour of signal processing*. Academic Press, 1998.

- [30] R. Isermann. Model based fault detection and diagnosis methods. In *Proceedings of the American Control Conference*, volume 3, pages 1605–1609, 1995.
- [31] P. Pennacchi, N. Bachschmid, and A. Vania. A model-based identification method of transverse cracks in rotating shafts suitable for industrial machines. *Mechanical Systems and Signal Processing*, 20(8):2112–2147, 2006.
- [32] A.S. Sekhar. On-line rotor fault identification by combined model and signal based approach. *Noise and Vibration Worldwide*, 35(7):16–30, 2004.
- [33] M. Feldman and S. Seibold. Damage diagnosis of rotors: application of Hubert transform and multihypothesis testing. *Journal of Vibration and Control*, 5(3):421–442, 1999.
- [34] D. Guo and Z.K. Peng. Vibration analysis of a cracked rotor using Hilbert-Huang transform. *Mechanical Systems and Signal Processing*, 21:3030–3041, 2007.
- [35] S. A. Adewusi. Wavelet analysis of vibration signals of an overhang rotor with a propagating transverse crack. *Journal of Sound and Vibration*, 5:777–793, 2001.
- [36] S. Prabhakar, A. S. Sekhar, and A. R. Mohanty. Detection and monitoring of cracks in a rotor-bearing system using wavelet transforms. *Mechanical Systems and Signal Processing*, 15:447–450, 2001.
- [37] A. S. Sekhar. Crack detection through wavelet transform for a run-up rotor. *Journal of Sound and Vibration*, 259:461–472, 2003.
- [38] B. Liu. Selection of wavelet packet basis for rotating fault diagnosis. *Journal of Sound and Vibration*, 248:567–582, 2005.
- [39] C. Nagaraju, K. Narayana Rao, and K. Mallikarjuna Rao. Application of 3d wavelet transforms for crack detection in rotor systems. *Sadhana*, 34:407–419, 2009.
- [40] D. Gu, J. Kim, T. Kelimu, S. Huh, and B. Choi. Evaluation of the use of envelope analysis and DWT on AE signals generated from degrading shafts. *Materials Science and Engineering*, 177:1683–1690, 2012.
- [41] J. Sanz, R. Perera, and C. Huerta. Fault diagnosis of rotating machinery based on auto-associative neural networks and wavelet transforms. *Journal of Sound and Vibration*, 302:677–683, 2007.
- [42] G.F. Bin, J.J. Gao, X.J. Li, and B.S. Dhillon. Early fault diagnosis of rotating machinery based on wavelet packets-empirical mode decomposition feature extraction and neural network. *Mechanical Systems and Signal Processing*, 27:696–711, 2012.
- [43] Q. Hu, Z. He, Z. Zhang, and Y. Zi. Fault diagnosis of rotating machinery based on improved wavelet package transform and SVMs ensemble. *Mechanical Systems and Signal Processing*, 21:668–705, 2007.
- [44] H. Li, L. Fu, and H. Zheng. Bearing fault diagnosis based on amplitude and phase map of Hermitian wavelet transform. *Journal of Mechanical Science and Technology*, 25(11):2731–2740, 2011.

- [45] Q. Du and S. Yang. Application of the EMD method in the vibration analysis of ball bearings. *Mechanical Systems and Signal Processing*, 21:2634–2644, 2007.
- [46] B.D. Forrester. *Detection and classification of incipient faults in gears and bearings*. Chapter 4, PhD. Thesis, University of Technology, Swinburne, Australia, 1996.
- [47] M. Lebold, K. McClintic, R. Campbell, C. Byington, and K. Maynard. Review of vibration analysis methods for gearbox diagnostics and prognostics. In *Proceedings of the 54th Meeting of the Society for Machinery Failure Prevention Technology*, volume 1(4), pages 623–634, Virginia Beach, VA, May 2000.
- [48] R. Moreno. *Detección y clasificación de fallos incipientes en engranajes y rodamientos*. Capítulo 2, PhD. Tesis, University of Castilla la Mancha, 2010.
- [49] J.A. Keller. *Vibration Monitoring of UH-60A Main Transmission Planetary Carrier Fault*. U.S. ARMY AMCOM. Aviation Engineering Directorate, 2003.
- [50] R.B. Randall, J. Antoni, and S. Chobsaard. A comparison of cyclostationary and envelope analysis in the diagnosis of rolling element bearings. In *ICASSP'00 Proceedings of the Acoustics, Speech, and Signal Processing*, volume 6, pages 3882–3885, 2000.
- [51] F.E. Hernández-Montero and M. Gutiérrez-García. Enfoques del análisis de envolvente al procesamiento de vibraciones para el diagnóstico de maquinarias. *Ingeniería Mecánica*, 13:31–40, 2010.
- [52] G. Yujie, L. Jingyu, L. Jie, L. Zhanhui, and Z. Wentao. A method for improving envelope spectrum symptom of fault rolling bearing based on the auto-correlation acceleration signal. *Applied Mechanics and Materials*, 275:856–864, 2013.
- [53] M. Barakat, M. El Badaoui, and F. Guillet. Hard competitive growing neural network for the diagnosis of small bearing faults. *Mechanical Systems and Signal Processing*, 2013.
- [54] Y. Zhang, H. Zuo, and F. Bai. Classification of fault location and performance degradation of a roller bearing. *Measurement*, 46:1178–1189, 2013.
- [55] L.L. Jiang, B.B. Li, and X.J. Li. An improved HHT method and its application in fault diagnosis of roller bearing. *Applied Mechanics and Materials*, 273:264–268, 2013.
- [56] K. Al-Raheem and W. Abdul-Karem. Rolling bearing fault diagnostics using artificial neural networks based on laplace wavelet analysis. *International Journal of Engineering, Science and Technology*, 2:278–290, 2010.
- [57] C. Castejón, O. Lara, and J.C. García-Prada. Automated diagnosis of rolling bearings using MRA and neural networks. *Mechanical Systems and Signal Processing*, 24:289–299, 2010.
- [58] M.J. Gómez, C. Castejón, and J.C. García-Prada. *Incipient Fault Detection in Bearings through the use of WPT energy and Neural Networks*. 2014.
- [59] X. Lou and K.A. Loparo. Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical Systems and Signal Processing*, 18(5):1077–1095, 2004.

- [60] L.J. Hadjileontiadis, E. Douka, and A. Trochidis. Crack detection in beams using kurtosis. *Computers and Structures*, 83(12-13):909–919, 2005.
- [61] Widem EU Project. Wheelset Integrated Design and Effective Maintenance. <http://www.widem.org/>, última consulta 02-2014, 2008.
- [62] S. Braun. *Discovering signal processing: an interactive guide for engineers*. John Wiley & Sons, 2008.
- [63] H. Nyquist. Certain topics in telegraph transmission theory. In *Trans. AIEE, Reprint as classic paper in: Proc IEEE vol 90, No2, Febr. 2002*, pages 617–644, April 1928.
- [64] H. Rubio. *Caracterización de defectos localizados en sistemas mecánicos rotativos mediante análisis de vibraciones*. Tesis Doctoral, Universidad Carlos III Madrid, 2003.
- [65] S. Mallat. A theory for multiresolution signal decomposition: The wavelet representation. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, volume 11(7), pages 674–693, 1989.
- [66] L. Vignolo, D.H. Milone, and H.L. Rufiner. Genetic wavelet packets for speech recognition. *Expert Systems with Applications*, 2011.
- [67] E. Avci and Z.H. Akpolat. Speech recognition using a wavelet packet adaptive network based fuzzy inference system. *Expert Systems with Applications*, 31(3):495–503, 2006.
- [68] P. Mercorelli. A denoising procedure using wavelet packets for instantaneous detection of pantograph oscillations. *Mechanical Systems and Signal Processing*, 35(1-2):137–149, 2013.
- [69] M.A. Tinati and B. Mozaffary. A wavelet packets approach to electrocardiograph baseline drift cancellation. *International Journal of Biomedical Imaging*, pages 1–9, 2006.
- [70] W.J. Wang and P.D. McFaden. Application of the wavelet transform to gearbox vibration analysis. In *Proceedings of the 16th Annual energy-Sources Technology Conference and Exhibition*, pages 13–20, 1993.
- [71] W.J. Wang and P.D. McFaden. Application of wavelets to gearbox vibration signals for fault detection. *Journal of Sound and Vibration*, 192:927–939, may 1996.
- [72] N. Baydar and A. Ball. Detection of gear failures via vibration and acoustic signals using wavelet transform. *Mechanical Systems and Signal Processing*, (17):787–804, 2003.
- [73] Z. Hou, M. Noori, and R. St. Amand. Wavelet-based approach for structural damage detection. *Journal of Engineering Mechanics*, 126:677–683, 2000.
- [74] A. Gentile and A. Messina. On the continuous wavelet transforms applied to discrete vibrational data for detecting open cracks in damaged beams. *Journal of Solid and Structures*, 40:295–315, 2003.
- [75] D.E. Newland. Wavelet analysis of vibration. *Journal of Vibration and Acoustics*, 116:409–416, 1994.
- [76] R. Moreno, P. Pintado, J.M. Chicharro, A.L. Morales, and A.J. Nieto. Methodology for evaluating neural networks input for gear fault detection. In *IEEE International Conference on Mechatronics*, pages 1–6, Malaga, April 2009.

- [77] A. Jensen and A. la Cour-Harbo. *Ripples in Mathematics*. Springer, 2000.
- [78] J. Smith. *Mathematics of the discrete Fourier Transform (DFT)*. W3K, 2003.
- [79] Q. Hu, Z. He, Z. Zhang, and Y. Zi. Fault diagnosis of rotating machinery based on improved wavelet package transform and SVMs ensemble. *Mechanical Systems and Signal Processing*, 21:688–705, 2007.
- [80] C. Shen, D. Wang, F. Kong, and P.W. Tse. Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier. *Mesurement: Journal of the International Measurement Confederation*, 46:1551–1564, 2013.
- [81] Y. Feng and F.S. Schlindwein. Normalized wavelet packets quantifiers for condition monitoring. *Mechanical Systems and Signal Processing*, 23:712–723, 2009.
- [82] G.A. Georgiou. Probability of detection (POD) curves: derivation, applications and limitations. In *HSE Books, Health and Safety, Executive Research Report 454, UK*, 2006.
- [83] S. Pal and A. Pal. *Pattern recognition, from classical to modern approaches*. W. Scientific (Ed.), 2001.
- [84] R. Duda, P. Hart, and P. Stork. *Pattern Classification*. John Wiley & Sons, 2001.
- [85] D. Brown, V. Corrnble, and C. Pittard. A comparison of decision tree classifiers with back-propagation neural networks for multimodal classification problems. *Pattern Recognition*, 26:953–961, 1993.
- [86] V. Sugumaran and K.I. Ramachandran. Automatic rule learning using decision tree for fuzzy classifier in fault diagnosis of roller bearing. *Mechanical Systems and Signal Processing*, 21:2237–2247, 2007.
- [87] V. Sugumaran and K.I. Ramachandran. Fault diagnosis of roller bearing using fuzzy classifier and histogram features with focus on automatic rule learning. *Expert Systems with Applications*, 38:4901–4907, 2011.
- [88] B. Mu noz Abella and L. Rubio. Detección e identificación de fisuras de frente semielíptico en ejes mediante la aplicación de algoritmos genéticos. In *XVIII Congreso Nacional de Ingeniería Mecánica*, number 48, 2010.
- [89] A. Widodo and B.S. Yang. Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical Systems and Signal Processing*, 21(6):2560–2574, 2007.
- [90] S. Yuan and F. Chu. Fault diagnostics based on particle swarm optimization and support vector machines. *Mechanical Systems and Signal Processing*, 21(4):1787–1798, 2007.
- [91] J. Yang, Y. Zhang, and Y. Zhu. Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension. *Mechanical Systems and Signal Processing*, 21-5:2012–2024, 2007.
- [92] B.K.N. Rao, P.S. Pai, and T.N. Nagabhushana. Failure diagnosis and prognosis of rolling - element bearings using artificial neural networks: A critical overview. In *Journal of Physics: Conference Series*, volume 364, pages 289–299, 2012.

- [93] B. Li, M.Y. Chow, Y. Tipsuwan, and J.C. Hung. Neural-network based motor rolling bearing fault diagnosis. *IEEE transactions on industrial electronics*, 47:1060–1069, 2000.
- [94] S. W. Liu, J. H. Huang, J. C. Sung, and C. C. Lee. Detection of cracks using neural network and computational mechanics. *Computer Methods in Applied Mechanics and Engineering*, 191:2831–2845, 2002.
- [95] T. Sorsa and H. Koivo. Application of artificial neural networks in process fault diagnosis. *Automatica*, 29:843–849, 1993.
- [96] W. Kinsner, V. Cheung, J. Pear, and T. Martin. Application of artificial neural networks in process fault diagnosis. *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics*, 36:196–203, 2006.
- [97] M.Y. Chow, R. Sharpe, and J. Hung. On the application and design of artificial neural networks for motor fault detection-part I. *IEEE Transactions on industrial electronics*, 40:181–188, 1993.
- [98] M.Y. Chow, R. Sharpe, and J. Hung. On the application and design of artificial neural networks for motor fault detection-part II. *IEEE Transactions on industrial electronics*, 40:189–196, 1993.
- [99] I. A. Abu-Mahfouz. A comparative study of three artificial neural networks for the detection and classification of gear. *International Journal of General Systems*, 34:261–277, 2005.
- [100] B. Samanta and R. Al-Balushi. Bearing fault detection using artificial neural networks and genetic algorithm. *Journal on Applied Signal Processing*, 3:366–377, 2004.
- [101] Spectra Quest Inc. Machinery Fault Simulator Lite. <http://spectraquest.com/machinery-fault-simulator/details/mfs-lt/>, última consulta 02-2014, 2006.
- [102] J.C. García-Prada and J.I. Pedrero. *Cálculo, construcción y ensayo de máquinas I. Vibraciones en máquinas*. UNED, 1993.
- [103] J. Romero. *Herramienta para la adquisición, procesamiento y monitorización de señales. Detección de fallos en ejes y rodamientos mecánicos*. Universidad Carlos III, Madrid, 2011.
- [104] S.M. Ross. *Introductory Statistics. Second Edition*. Elsevier, 2005.
- [105] W. Wang, F. Ismail, and F. Golnaraghi. Assesment of gear damage monitoring techniques using vibration measurements. *Mechanical Systems and Signal Processing*, 15(5):905–922, 2001.
- [106] M.A. Ibáñez. *Obtención de señales vibratorias y análisis estadístico para defectología en ejes ferroviarios*. Universidad Carlos III, Madrid, 2012.
- [107] R. Sánchez. *Registro y análisis de señales vibratorias de un eje ferroviario a escala para defectología*. Universidad Carlos III, Madrid, 2012.
- [108] M.J. Gómez and C. Castejón. Selecccion de funcionales óptimos. In *Proyecto Rankine 21, Internal Report, A.1-T.1-3*, 2012.
- [109] E. Pinto. *Análisis y evaluación de los niveles de energía obtenidos mediante WPT para defectología de ejes*. Universidad Carlos III, Madrid, 2012.

- [110] L.E. Moreno. *Ingeniería de control: modelado, análisis y control de sistemas*. Ariel, 2003.
- [111] L. Itoha. *Análisis del comportamiento ante vibración de un banco de ensayo de ejes ferroviarios*. Universidad Carlos III, Madrid, 2012.
- [112] M. Chow. *Methodologies for using neural networks and fuzzy logic technologies for motor incipient fault detection*. World Scientific, 1997.

Apéndice

Apéndice A

Hojas de características de los acelerómetros

En las figuras A.1, A.2 y A.3 se pueden consultar las hojas de características de los acelerómetros disponibles en la presente Tesis Doctoral mencionados en el la sección 6.2.1 .

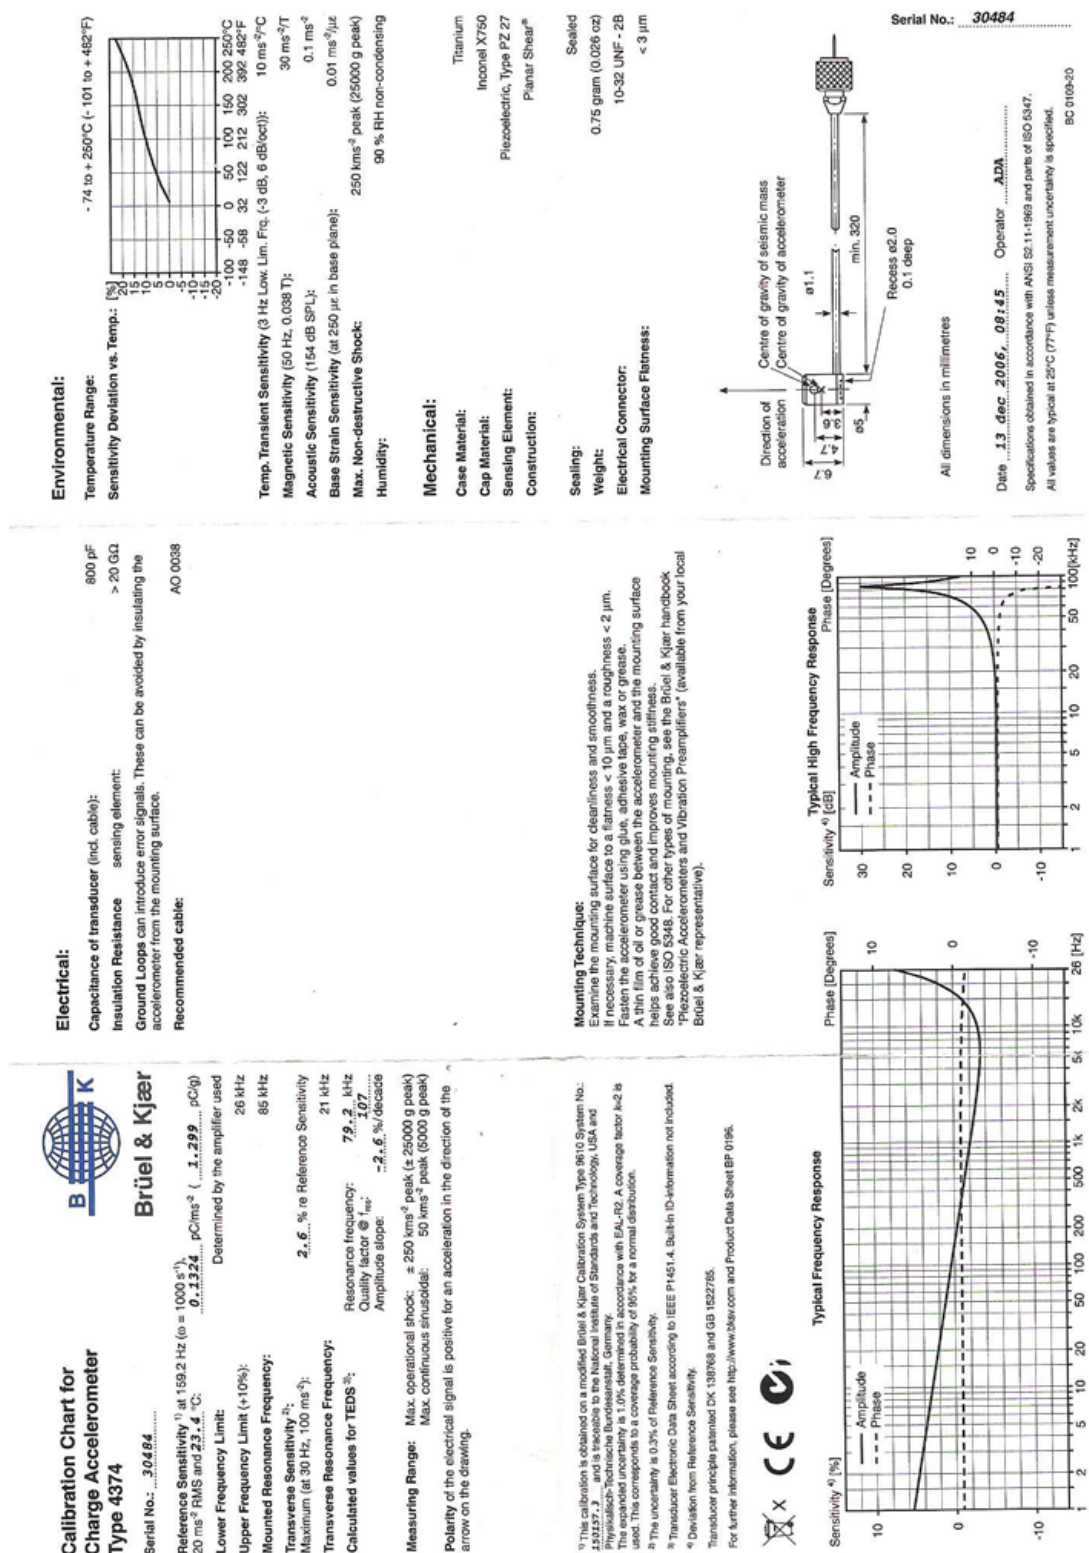


Figura A.1: Hoja de características del acelerómetro 1

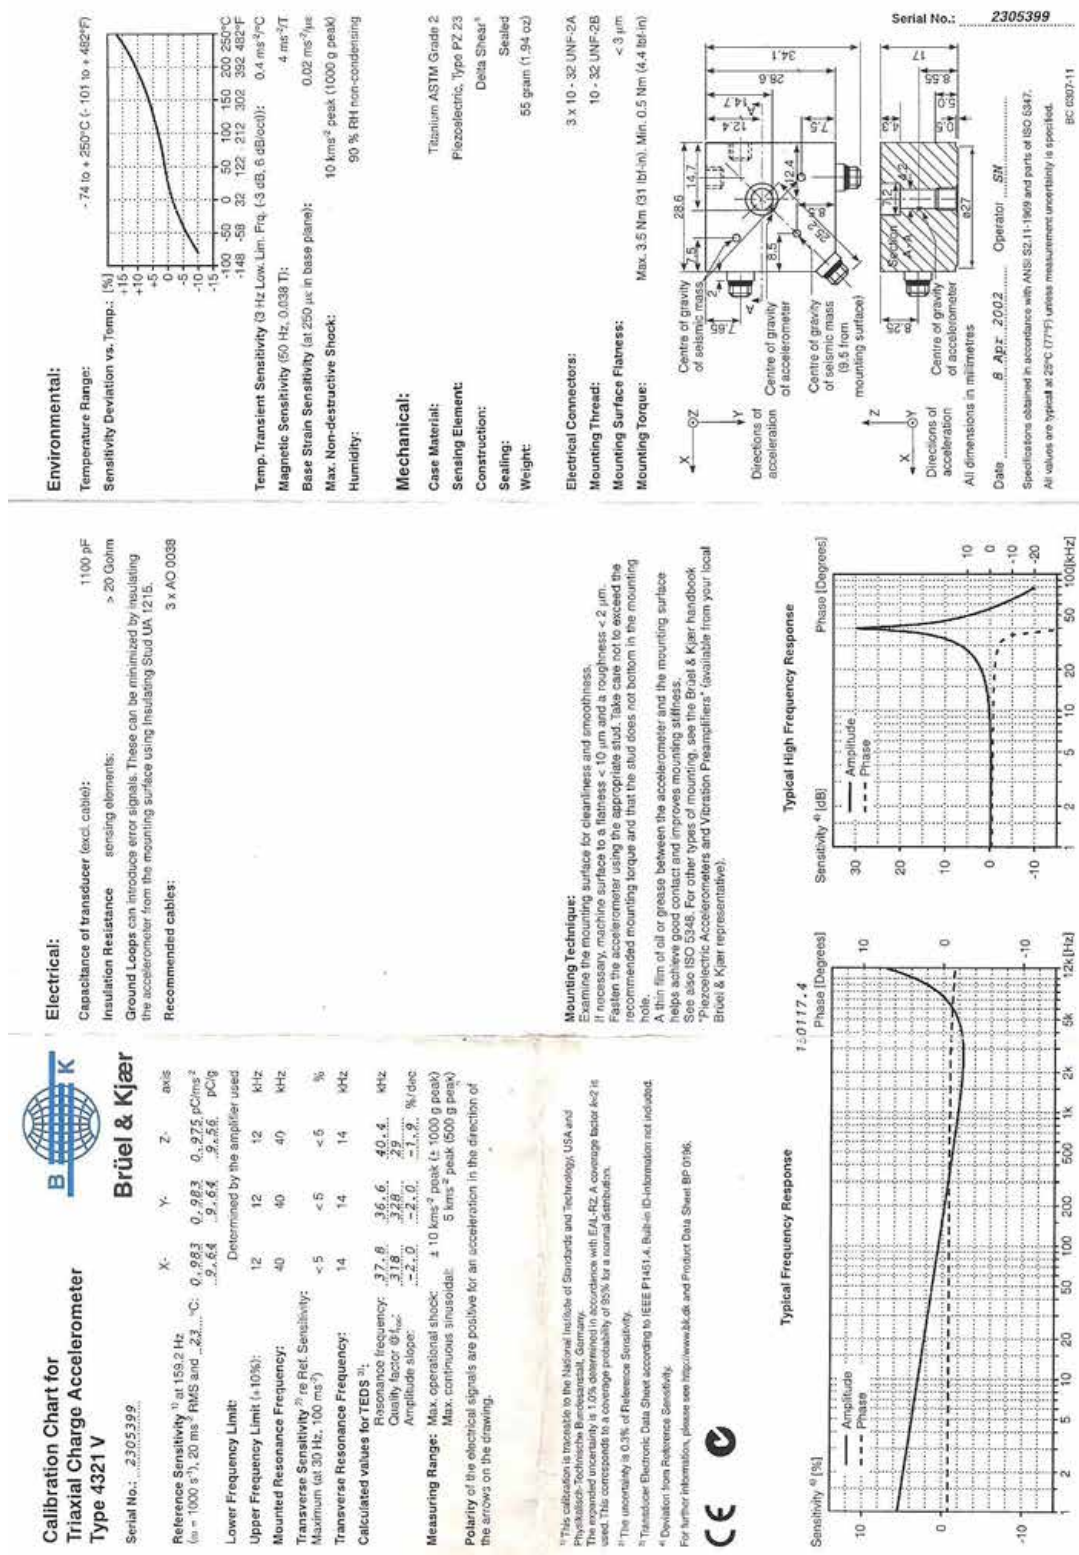


Figura A.2: Hoja de características del acelerómetro 2

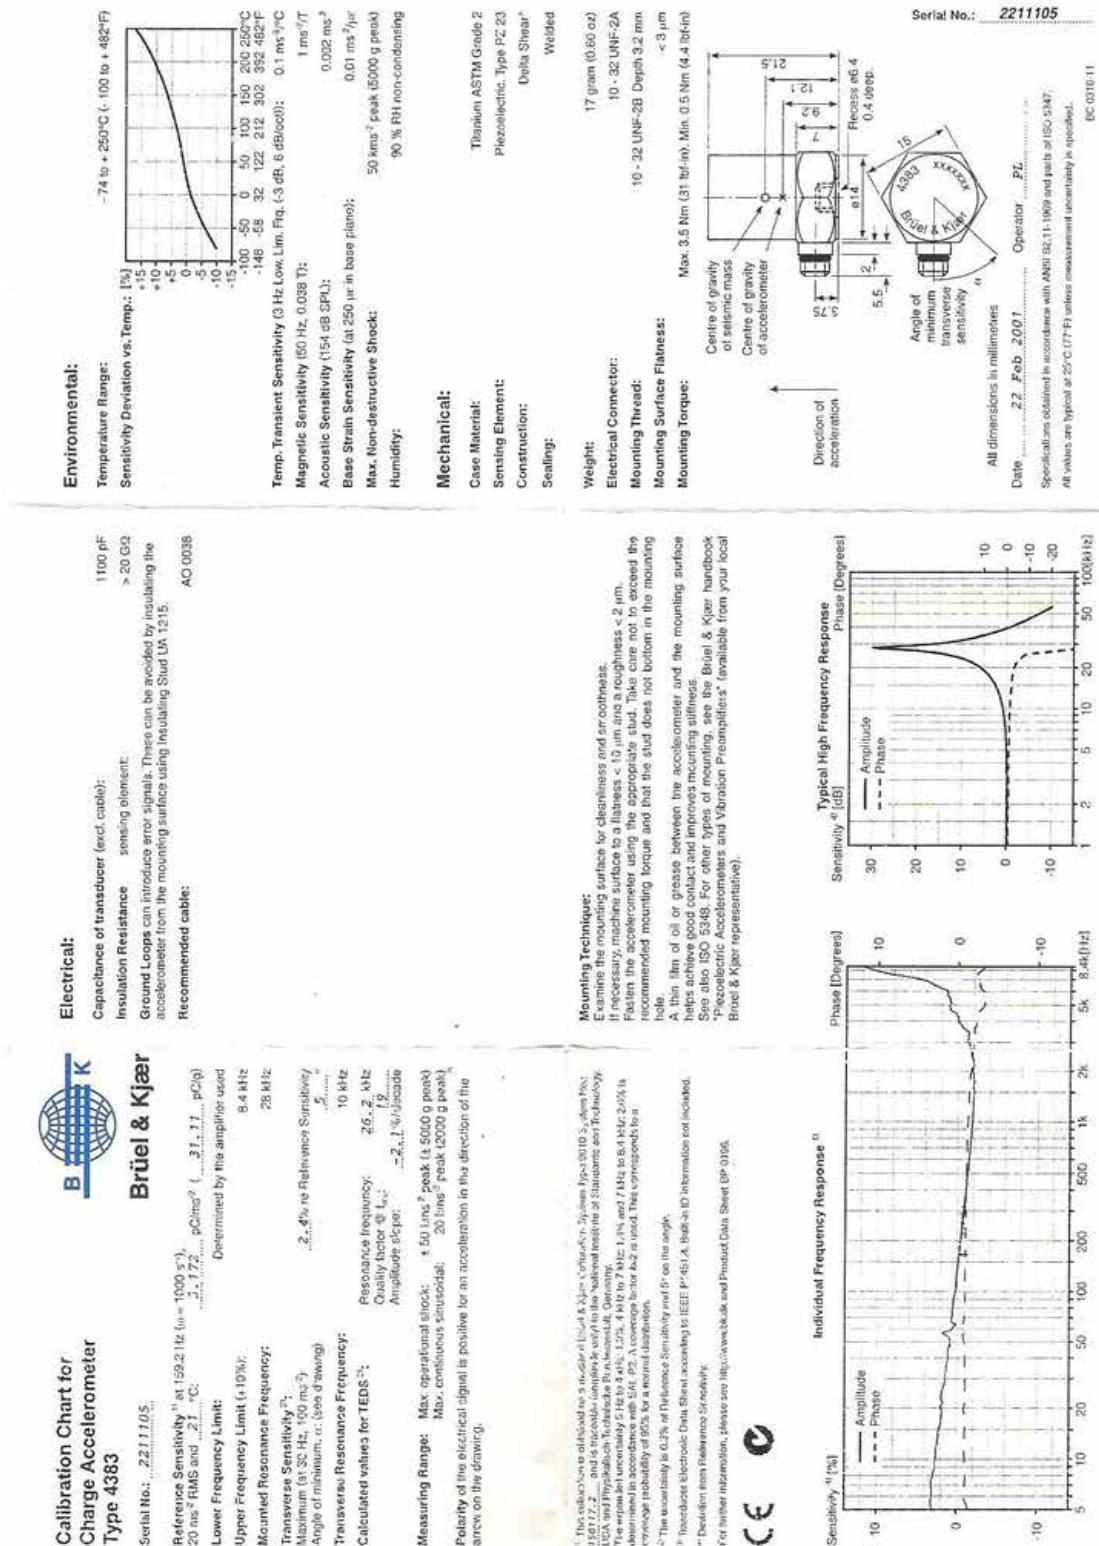


Figura A.3: Hoja de características del acelerómetro 3

Apéndice B

Protocolo de medidas

El protocolo de medidas seguido para la adquisición de datos consta de los siguientes pasos:

- Al inicio de la sesión, el primer paso es comprobar el montaje de la maquinaria, es decir, que todos los elementos están correctamente fijados.
- A continuación, se comprueban las conexiones de los equipos de medida. Se comienza comprobando la posición del acelerómetro ya que, debido a las vibraciones, puede ser desplazado de su posición. Las conexiones de los cables deben estar correctamente cerradas, y los cables deben estar fijados para no experimentar movimiento durante la adquisición (lo que podría introducir ruido). Además, no deben tocar al eje ni a ningún elemento mecánico en movimiento.
- Una vez realizadas estas comprobaciones, se cierra la compuerta de seguridad.
- En ese momento se arranca el motor y, por medio del regulador, se le hace girar a la velocidad de 1.200 r.p.m. para que el motor vaya alcanzando su temperatura de régimen.
- Mientras el motor va adquiriendo temperatura, se comprueban los parámetros del acondicionador de señal y del ordenador, que deben estar encendidos. Los parámetros del acondicionador de señal deben ser:
 - Filtro paso alto: 0,1Hz.
 - Filtro paso bajo: 3KHz.
 - Ganancia de la señal: 10 mV/V
 - Sensibilidad: 3,172 pC/ms⁻²

Los parámetros a fijar en el software de adquisición son:

- Frecuencia de muestreo: 6.000Hz.
 - Número de puntos de cada señal: 16.384
 - Número de ciclos a medir: 100
 - Tiempo a esperar entre ciclos: 1s
- Comenzar la adquisición. Cada sesión de medida se considera un grupo de seis medidas como esta. La secuencia de velocidades será alternada de esta forma: 20Hz, 40Hz, 60Hz,

20Hz, 40Hz, 60Hz para evitar sobrecalentamientos y garantizar que la temperatura al inicio sea siempre parecida. Cada medida se almacena por orden en una carpeta con nombre la fecha, y con los siguientes sufijos correspondientes: -1, -2-, -3, -4, -5, -6. De esta manera, se sabe que los sufijos -1 y -4 se corresponden con las velocidades de 20Hz, el -2 y el -5 con la velocidad de 40Hz y el -3 y el -6 a 60Hz.

- Una vez finalizada la adquisición, el grupo total de medidas obtenido se almacena en una carpeta con el nombre correspondiente a la fecha en la que se ha realizado la adquisición. A continuación se rellena una tabla excel donde se especifican todos los parámetros de medida utilizados, especialmente el nivel de defecto del eje y la fecha. Se genera un nuevo nivel de defecto en el caso de que o bien se hayan completado las medidas de 50 grupos si se trata de un eje sano, o bien se hayan tomado medidas de 16 grupos para un nivel de defecto determinado para las tres velocidades.
- Una vez finalizados los ensayos se apagan y desconectan todos los dispositivos.

Apéndice C

Aplicación de la metodología propuesta a rodamientos

Para el diagnóstico de rodamientos utilizando la metodología general propuesta en el presente trabajo, se utiliza como patrón la energía WPT, debido a los buenos resultados arrojados en ejes, por lo tanto el estudio se centra en seleccionar los parámetros locales óptimos de la señal.

Como se explicó en el capítulo 2, los rodamientos son elementos complejos debido a que están compuestos por varios elementos, y por tanto cada uno de ellos puede fallar. En este caso, las frecuencias teóricas de fallo son bien conocidas, por lo que no será necesario realizar un modelo teórico. En una primera aproximación se seleccionarán como posibles patrones válidos, la energía de los paquetes que contengan las frecuencias teóricas de fallo.

Para la segunda aproximación, se procederá exactamente de la misma manera que para ejes. Es decir, se utilizará la energía obtenida mediante WPT de las señales a distintos niveles de descomposición, y con ellas se alimentarán distintas redes neuronales. El proceso que ofrezca mejor diagnóstico se seleccionará como óptimo.

Los datos de rodamientos utilizados en este trabajo, se tomaron para la realización de la Tesis Doctoral de Omar Lara, [4]. En las siguientes secciones se explicarán tanto el procedimiento para la obtención de las señales, como las dos aproximaciones utilizadas y sus resultados.

C.1. Adquisición de datos

Las señales vibratorias fueron obtenidas de un banco de ensayos perteneciente al Departamento de Ingeniería Mecánica de la UNED. Los rodamientos ensayados fueron FAG 7206 B, que son rodamientos de bolas, que fueron ensayados a tres velocidades de rotación diferentes, 10, 20 y 30Hz, controladas mediante un tacómetro óptico. El banco de ensayos se muestra en la figura C.1.

En la figura C.1, los primeros elementos observados, de derecha a izquierda, son cilindros neumáticos axiales y radiales, que aplican cargas de 2,5 y 3 bares respectivamente. A continuación se puede observar el montaje de los rodamientos. La transmisión se realiza mediante una correa conectada al motor.

La cadena de medida está compuesta de nuevo por un acelerómetro B&K 4383, un amplificador B&K NEXUS y una tarjeta de adquisición DAS-1200 Keithley. La frecuencia de muestreo utilizada fue de 5.000Hz, y cada señal adquirida tiene 5.120 puntos.

Las primeras medidas fueron realizadas con rodamientos sanos. Después, se indujeron varios



Figura C.1: Banco de ensayos utilizado para la toma de medidas de rodamientos. Laboratorio de la UNED

defectos incipientes entre los que se incluían el defecto en pista interna, en pista externa y el de bola, los más comunes en rodamientos. Para los defectos en pista interna y externa, se realizaron fisuras de 2mm mediante electroerosión. En el caso del defecto en bola, se realizaron varios huecos en la superficie.

Finalmente, se obtuvieron 588 señales, 196 por cada velocidad, y 49 para cada condición de fallo.

Estas señales han sido utilizadas previamente para el diseño de otros sistemas de diagnóstico, basados en MRA, que fueron publicados en [57].

C.2. Análisis de las energías WPT de las frecuencias teóricas de fallo

En este caso se recurrirá a las frecuencias de fallo teóricas para la selección de parámetros locales mediante la primera aproximación. Estas frecuencias dependen de la configuración del rodamiento y de la velocidad de rotación. Para los defectos inducidos en este trabajo, que son el defecto en pista interna, en pista externa y en bola, las frecuencias teóricas de fallo fueron expuestas en las ecuaciones 2.5, 2.6 y 2.7. Para el caso de los rodamientos tratados en este trabajo, los FAG 7206 B, las frecuencias de fallo se muestran en la tabla C.1.

Utilizando nuevamente como Wavelet madre la db6, y un nivel de descomposición 9, se calcula la WPT y posteriormente las energías. Los paquetes que contienen las frecuencias teóricas de fallo son seleccionados directamente para un análisis previo. Comparando las energías de los paquetes seleccionados para rodamiento sano y defectuoso, no se observa que los datos puedan ser separables estableciendo un valor umbral para ningún caso de defecto ni de velocidad.

Debido al fracaso de este primer método, se recurre a entrenar una serie de redes neuronales utilizando los coeficientes de la WPT (un total de 11) de los paquetes seleccionados. Los resultados

Tipo de fallo	Frecuencia (Hz)		
	10Hz	20Hz	30Hz
BPFI	75,39	150,78	226,17
BPFR	46,69	93,38	140,07
BPFO	54,60	109,21	163,83

Tabla C.1: Frecuencias de fallo de los rodamientos FAG 7206 B

en este caso tampoco son buenos, y no se obtiene ninguna red con una tasa de acierto global mayor del 50 %.

A la vista de los resultados, se puede afirmar que, en este caso, ni la energía ni los coeficientes de la WPT de las frecuencias teóricas de fallo pueden ser utilizados para establecer un método de diagnosis fiable.

C.3. Análisis global de la energía WPT de las señales experimentales

Como segunda aproximación para la selección de parámetros locales de la WPT de la señal se utilizará el mismo método que para ejes. De nuevo se utilizarán las energías obtenidas mediante WPT a distintos niveles de descomposición (del 2 al 9). Estas energías serán los patrones de entrada para los entrenamientos de distintas redes neuronales de arquitectura RBF.

De nuevo en este caso se diferenciará entre niveles de descomposición altos y bajos: para los bajos, se tomarán todos los paquetes generados, y para los altos, la combinación de los 10 que presentan las máximas diferencias para condición de fallo, de forma análoga al caso de ejes.

C.3.1. Diseño del sistema de clasificación: redes neuronales RBF

En el caso de los rodamientos, las redes se entrenarán con cuatro salidas diferentes, debido a que se obtienen muy buenos resultados, y las redes son capaces de distinguir entre los diferentes tipos de defecto analizados.

De forma análoga al caso de ejes, se buscará una configuración óptima de las redes RBF para cada velocidad, de forma que a cada una haya un sistema de clasificación que sepa distinguir entre los patrones que provienen de rodamientos sanos y de cada tipo de defecto analizado. En la tabla C.2, se muestran los parámetros comunes para los entrenamientos de las redes.

C.3.2. Resultados

Una vez optimizado el valor de *spread* para cada condición de velocidad y nivel de descomposición, se dispone de un total de 24 redes neuronales optimizadas, 8 para cada velocidad. Los resultados de número de neuronas en la capa oculta obtenidos, que son un claro indicador del coste computacional para el entrenamiento de las redes, así como las tasas de acierto, se presentan en la figura C.2 en función del nivel de descomposición utilizado.

Como se puede observar, el nivel de descomposición 4 parece ser el óptimo para todas las velocidades, ya que maximiza las tasas de acierto y minimiza el número de neuronas en la capa oculta. Una vez conocido este valor, y el de *spread* óptimo para cada caso de velocidad, se vuelven

Normalización de valores de entrada	En $[-1;1]$	
Tipo de aprendizaje	Supervisado	
Número de salidas	4	
Normalización de los valores de salida	$[-1,1]$	
Distribución de datos de entrada	Training	75 %
	Test	25 %
Criterio de parada	<i>Goal</i>	0,1-0,2
	Neuronas en la capa oculta	700
<i>Spread</i>	0,2-2	

Tabla C.2: Constantes utilizadas para el diseño de RBFs en rodamientos




Figura C.2: Gráficas para la selección del valor de descomposición óptimo para el caso de rodamientos (a) Número de neuronas en función del nivel de descomposición (b) Tasas de acierto obtenidas en función del nivel de descomposición

a entrenar las mismas redes utilizando en este caso un valor máximo admisible de error para el entrenamiento (*goal*) de 0,1.

Los resultados obtenidos para cada caso de velocidad, se muestran en la tabla C.3.

Como se puede observar, las tasas de acierto se han mejorado al utilizar un valor menor para el *goal*, sin embargo el coste computacional ha aumentado. En este caso, como la red cuenta con 4 salidas, los resultados se presentarán en cuatro gráficos distintos. En cada uno de ellos, se presentarán las salidas de la red cuando a la entrada se le proporcionan cada una de las cuatro condiciones distintas: rodamiento sano, rodamiento con defecto en pista interna, en bola, y en pista externa. En la figura C.3 se presentan estos resultados parciales de clasificación.

A la vista de los resultados se puede afirmar que este método permite una detección muy fiable de defectos incipientes en rodamientos, y no solamente detecta los defectos sino su localización a las tres velocidades analizadas. Además en los casos de 20 y 30Hz no existe ninguna falsa alarma, y para el caso de 10Hz solamente un 0,5 %. La probabilidad de no detectar un defecto es muy baja en los tres casos, sin embargo, en este sentido, los mejores resultados se obtienen a 10 y 20Hz, donde aunque en algunos casos los defectos se confundan con otros, solamente en

Velocidad(Hz)	Neuronas en la capa oculta	Tasa de acierto (%)
10	60	97,13
20	87	97,26
30	145	95,74

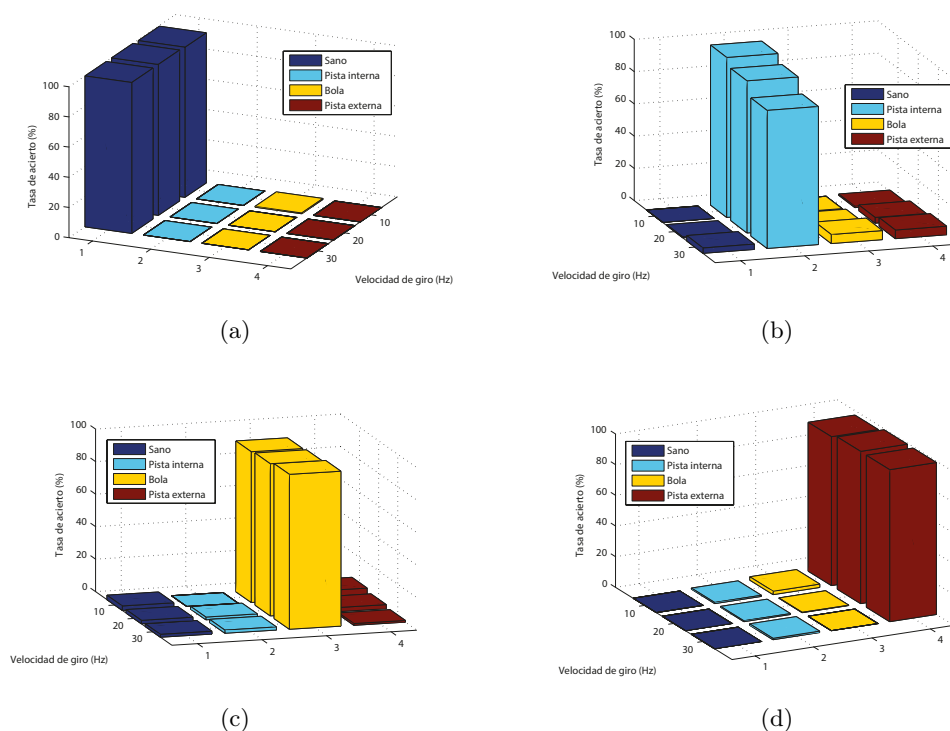
Tabla C.3: Resultados obtenidos para un *goal* de 0,1

Figura C.3: Tasa de acierto (%) para las tres redes entrenadas a las distintas velocidades (Hz) (a) Clasificación de rodamiento sano (b) Clasificación de un rodamiento con defecto en pista interna (c) Clasificación de un rodamiento con defecto en bola (d) Clasificación de un rodamiento con defecto en pista externa

aproximadamente 2% de las ocasiones se diría que un rodamiento defectuoso está sano. De esta manera, en este caso los resultados óptimos se obtienen a 20Hz, aunque a las tres velocidades se obtienen muy buenos diagnósticos.

C.4. Resumen de la aplicación a rodamientos

Con el fin de generalizar los métodos de diagnóstico propuestos para ejes en los capítulos anteriores, se aplican las mismas técnicas. En el caso de los rodamientos, se han utilizado señales vibratorias obtenidas de rodamientos a tres velocidades diferentes de 10, 20 y 30Hz, y en cuatro condiciones distintas que son: rodamiento sano, con defecto en pista interna, con defecto en bola, y en pista externa.

Debido a los buenos resultados en ejes, se ha recurrido directamente al análisis de la energía WPT, por lo que el estudio se ha centrado en la selección de los parámetros locales de la señal. En la primera aproximación se han utilizado las energías WPT de las bandas de frecuencia que contenían las frecuencias teóricas de fallo, sin embargo, no se han conseguido resultados de detección fiables. Sin embargo, mediante la segunda aproximación, utilizando las redes neuronales, sí se obtuvieron buenos resultados de clasificación. En este caso no se observan grandes diferencias en los resultados con la velocidad, aunque la que mejores resultados de clasificación ofrece es la intermedia, de 20Hz. En cuanto al nivel de descomposición, el óptimo resulta ser el 4. Aunque en el caso de los ejes era el 5, vuelve a ocurrir que los resultados de las redes que utilizan todos los paquetes para el entrenamiento, ofrecen mejores diagnósticos que las que utilizan sólo algunos. Por tanto, se puede concluir que los efectos producidos por un defecto son más visibles mediante el análisis de todo el rango de la señal que con el de determinadas bandas finas.

Mediante esta técnica, se observa que a la velocidad de 20Hz se obtiene un sistema de clasificación con tasas de acierto muy altas, con cero falsas alarmas y con menos del 2 % de probabilidad de no detección de un defecto incipiente. La distinción entre tipos de fallo además es muy precisa.